



TESIS DOCTORAL

IDENTIFICACIÓN Y LOCALIZACIÓN DE MÚLTIPLES FUENTES DE DESCARGA PARCIAL USANDO ANÁLISIS DE COMPONENTES INDEPENDIENTES

Autor:

Carlos Allan Boya Lara

Director y tutor:

Marta Ruiz Llata

DEPARTAMENTO DE TECNOLOGÍA ELECTRÓNICA

Leganés, septiembre 2017



Universidad
Carlos III de Madrid
www.uc3m.es

TESIS DOCTORAL

IDENTIFICACIÓN Y LOCALIZACIÓN DE MÚLTIPLES FUENTES DE DESCARGA PARCIAL USANDO ANÁLISIS DE COMPONENTES INDEPENDIENTES

Autor: Carlos Allan Boya Lara

Director: Marta Ruiz Llata

Firma del Tribunal Calificador:

Firma

Presidente:

Vocal:

Secretario:

Calificación:

Leganés, de de

Agradecimientos

Agradezco: a mi familia: mi madre Hercilia, mi padre Carlos, mi hermana Alma y a mi hermano Diener. Ellos son mis pilares sin los cuales sólo sería una hoja sin rumbo llevada por el viento de la decepción. Agradezco a mi tutora Marta que me ha tenido paciencia y que siempre creyó en mí. Sin ella jamás habría escrito algo que valiera la pena. Agradezco a mi país que, a través de la Secretaría Nacional de Ciencia, Tecnología e innovación (SENACYT) y el Instituto de Formación para el Aprovechamiento Humano (IFARHU) me dio el apoyo económico. Agradezco a la Universidad Carlos III de Madrid por darme la oportunidad de estudiar en un centro de alto nivel y aprender de un cúmulo de profesores inigualables. Agradezco a España por su excelente sistema de investigación, que sé que pasa por problemas actualmente, pero que aun así sigue produciendo.

Quiero agradecer muy especialmente a Julio Posada, mi fren. Siempre me has dado todo tu apoyo y comprensión. En España me hice de amigos excelentes, como Guillermo, Luis el mex, Robinson, Danny el genio, Jesús, el Dr. Jose Antonio, Pablo Acedo, Luca Leggio, Luca Martino, Mónica, Ehsan, Plinio, David Barrios, Jenny y Diana. En Panamá agradezco a Barria, Mazza, Erwin, Roderick, mis primis Luz Alba y Charito, mi abuelita Antonia y mi finado abuelo Fausto, todos mi tías y tíos, y mis primos que siempre están atentos; a Iveth y Rolando, Luz Alba Andrade, Kathia, al Dr. Víctor Sanchez, Victor Cabrera, Farah y Tomasa.

Desde mi corazón, MUCHAS GRACIAS A TODOS.

Resumen

La fiabilidad de los equipos eléctricos depende directamente de la integridad del aislamiento eléctrico. La detección, identificación y localización de las Descargas Parciales (DP) se utiliza como una herramienta para obtener información que permite evaluar el estado del aislamiento.

Para la detección existen diferentes métodos, siendo los principales: el eléctrico, el acústico y el electromagnético. Posterior a la detección se aplican métodos para la identificación de las descargas y otros métodos que se enfocan en su localización. Normalmente, estos métodos asumen la presencia de una sola fuente de descarga, sin embargo, en ambiente reales, siempre existe la posibilidad de varias fuentes de descarga localizadas en diferentes puntos del aislante. Aunque se han propuestos métodos con el objetivo de identificar en ambientes de múltiples descargas, sus resultados sólo indican la presencia de más de una descarga o logran clasificar si no existe solapamiento.

Las señales provenientes de más de una fuente DP se mezclan en los sensores, efecto que cambia sus características en tiempo y frecuencia de tal forma que se distorsiona la forma de onda de la señal y dificulta el cálculo de los tiempos de llegada o TDOA (Time Delay On Arrival). Este problema no permite que los métodos tradicionales de identificación y localización trabajen adecuadamente. La tesis doctoral propone un método para separar estas mezclas en las fuentes originales de DP. El método utiliza Análisis de Componentes Independientes (ICA, siglas en inglés de Independent Component Analysis) y se demuestra su utilidad aplicándolo a señales detectadas por los métodos de detección acústico y electromagnético. Estos métodos son llamados métodos de detección no convencionales y se aplican como una alternativa o complemento al método eléctrico convencional.

ICA, recupera la forma de onda original de cada fuente y de manera automática las identifica. Está sustentado en una sólida teoría matemática y estadística y que ha sido desarrollada específicamente para solucionar el problema de mezclado de señales en ambiente reales. Además, es transparente al tipo de señales que procesa; es decir, no es afectado por las características particulares de un proceso, sólo es necesario que sean

estadísticamente independientes, lo que ofrece un marco general para trabajar con todo tipo de señales.

En la tesis se utiliza el algoritmo ICA-Amari para mezclas convolutivas. Es aplicado a mezclas acústicas generadas en una plataforma de ensayos en las cuales se simulan descargas de tipo superficial e internas. En estas pruebas se comprueba como el mezclado afecta las características de la forma de onda de las señales originales dificultando su identificación. Las mezclas son separadas en las señales originales lo que es validado utilizando patrones de energía en frecuencia. El algoritmo ICA-Amari estima parámetros de los cuales se pueden obtener los TDOA de cada fuente de DP con el objetivo de localizarlas.

Finalmente, ICA es aplicado a señales electromagnéticas detectadas por antenas UHF. En este caso se generan DP desde dos fuentes del mismo tipo, pero colocadas en diferentes posiciones espaciales. Las DP son del tipo superficial. Debido a que estas señales tienen características muy similares, un método tradicional de identificación puede llegar a generar falsos positivos en estas condiciones, sin embargo, ICA identifica las dos DP e incluso ofrece información de los TDOA para la localización.

Abstract

The reliability of electrical equipment depends directly on the integrity of the electrical insulation. The detection, identification, and location of Partial Discharge (PD) is used as a tool to obtain information that allows to evaluate the state of the insulation.

For detection there are different methods, the main ones being electric, acoustic, and electromagnetic. After detection methods are applied for the identification of discharges and other methods that focus on their location. Normally, these methods assume the presence of a single source of discharge, however, in real environments, there is always the possibility of several sources of discharge located in different points of the insulation. Although methods have been proposed with the aim of identifying multiple discharge, their results only indicate the presence of more than one discharge or they can classify if there is no overlap.

Signals from more than one DP source are mixed in the sensors, an effect that changes their characteristics in time and frequency in a way that distorts the signal waveform and makes difficult to calculate the arrival times or TDOA (Time Delay On Arrival). This problem does not allow traditional identification and localization methods to work properly. The doctoral thesis proposes a method to separate these mixtures in the original sources of DP. The method uses Independent Component Analysis (ICA) and demonstrates its usefulness by applying it to signals detected by acoustic and electromagnetic detection methods. These methods are called non-conventional methods and are applied as an alternative or complement to the conventional electrical method.

ICA, retrieves the original waveform from each source and automatically identifies them. It is based on a solid mathematical and statistical theory and has been developed specifically to solve the problem of signal mixing in real environments. In addition, it is transparent to the type of signals it processes; it is not affected by the characteristics of a process and it is only necessary that signals are statistically independent. This provides a general framework for working with all kinds of signals.

The thesis uses the ICA-Amari algorithm for convolutive mixtures. It is applied to acoustic mixtures generated in a test platform in which superficial and internal type

discharges are simulated. In these tests, it is verified how the mixing affects the characteristics of the waveform of the original signals, making it difficult to identify them. The mixtures are separated into the original signals which is validated using frequency energy patterns. The ICA-Amari algorithm estimates parameters from which the TDOA can be obtained from each DP source to locate them.

Finally, ICA is applied to electromagnetic signals detected by UHF antennas. In this case DP is generated from two sources of the same type, but placed in different spatial positions. DPs are of the superficial type. Because these signals have very similar characteristics, a traditional method of identification may lead to false positives under these conditions, however, ICA identifies the two PDs and even provides TDOA information for localization.

Índice

Agradecimientos	II
Resumen	IV
Abstract	VI
1. INTRODUCCIÓN	1
1.1. Generación de las descargas parciales	2
1.1.1. Mecanismo de generación	3
1.1.2. Tipos de descargas parciales	4
1.1.2.1. Descargas parciales internas	5
1.1.2.2. Descargas parciales superficiales	5
1.1.2.3. Descargas parciales de tipo corona	7
1.2. Detección de las descargas parciales	8
1.2.1. Detección eléctrica	8
1.2.2. Detección por medio de gases	9
1.2.3. Detección óptica	9
1.2.4. Detección acústica	10
1.2.5. Detección electromagnética	10
1.3. Objetivos de la tesis	11
1.4. Estructura del documento	12
2. DETECCIÓN, IDENTIFICACIÓN Y LOCALIZACIÓN DE DP	13
2.1. Introducción	13
2.2. Revisión histórica	14
2.3. Métodos de detección de descargas parciales	15
2.3.1. Método eléctrico	15
2.3.2. Método acústico	18
2.3.3. Método electromagnético	22
2.4. Identificación de las descargas parciales.	24

2.4.1. Patrones de fase resuelta (PRPD).	24
2.4.2. Tiempo resuelto.	28
2.5. Localización de las descargas parciales	34
2.5.1. Estimación de TDOA por el método de umbral	38
2.5.2. Estimación de TDOA por el método del primer pico	39
2.5.3. Estimación de TDOA por el método energía acumulada	39
2.5.4. Método de correlación cruzada	40
2.6. Identificación múltiples descargas parciales	41
2.6.1. Múltiples fuentes de PD con métodos de identificación basados en PRPD	42
2.6.2. Múltiples fuentes de PD con métodos de identificación basados en tiempo resuelto	44
2.7. Discusión sobre los métodos de identificación para múltiples DP	51
3. ANÁLISIS DE COMPONENTES INDEPENDIENTES	53
3.1. Introducción	53
3.2. Formulación del problema	56
3.3. Algoritmos para ICA	59
3.3.1. Modelo paramétrico de separación	59
3.3.2. Criterios para la búsqueda independencia estadística	62
3.3.2.1. Maximización de la no gaussianidad	64
3.3.2.2. Minimización de la mutua información.	70
3.4. Separación de mezclas convolutivas	78
3.4.1. Algoritmo de ICA para separación de mezclas convolutivas	79
3.5. Conclusiones del capítulo	82
4. IDENTIFICACIÓN Y LOCALIZACIÓN DE MÚLTIPLES DP CON ICA	83
4.1. ICA para separación de señales acústicas de DP.	83
4.2. Señales de DP para los experimentos	84
4.3. Identificación utilizando mezclas sintéticas	88
4.4. Identificación utilizando mezclas acústicas reales	95
4.4.1. Generación de señales acústicas reales	99

4.4.2. Generación de las mezclas	100
4.4.3. Separación de mezclas utilizando el algoritmo ICA-Amari	101
4.5. Análisis de parámetros del algoritmo ICA-Amari	103
4.5.1. La función de activación	103
4.5.2. La longitud de los filtros, tasa de aprendizaje e iteraciones	104
4.6. Localización de múltiples fuentes de DP	107
4.7. Conclusiones del capítulo	113
5. ICA PARA LA DETECCIÓN ELECTROMAGNÉTICA DE MÚLTIPLES DP	115
5.1. Generación de mezclas de emisiones electromagnéticas	115
5.1.1. Montaje experimental	116
5.1.2. Generación de mezclas	118
5.2. Filtrado del ruido	120
5.3. Separación e identificación utilizando el algoritmo ICA-Amari	121
5.4. Conclusiones del capítulo	124
6. APORTACIONES DE LA TESIS, TRABAJO FUTURO Y PUBLICACIONES	126
6.1. Aportaciones	126
6.2. Trabajo futuro	127
6.3. Publicaciones	128
7. REFERENCIAS	129

I. ÍNDICE DE FIGURAS

Figura 1.1. Gráficas de las tensiones y corriente asociadas a un evento de DP. Se muestra la tensión variable aplicada $u_T(t)$, en este caso AC, al aislante. La tensión $u_C(t)$ en la cavidad cuando existen y no existen DP y los umbrales dados por los valores de la tensión de ignición, $u_i(t)$ y el valor de la tensión de extinción, $u_e(t)$, en las dos polaridades. También se muestra la serie de pulsos de corriente inducidos las DP.....	4
Figura 1.2. Esquema representativo de varias cavidades generando DP internas. Las cavidades pueden encontrarse adyacentes a los electrodos o en medio de ellos.....	5
Figura 1.3. Esquema representativo para las DP tipo superficiales. En este tipo de DP el campo eléctrico es tangencial a la superficie del dieléctrico.	6
Figura 1.4. Un plato de policarbonato afectado por descargas parciales superficiales. Estas ramificaciones son como caminos conductivos a través de la superficie del aislante. Imagen obtenida desde: https://commons.wikimedia.org/wiki/File:Tracking1.jpg	7
Figura 1.5. Descargas parciales tipo corona alrededor de los herrajes del remate de una línea de alta tensión. Imagen obtenida desde: http://www.coloradowireandcable.com/uncategorized/the-corona-discharge-its-properties-and-uses/	8
Figura 1.6. Sección de la estructura metálica de una GIS. Se muestran las protuberancias en la superficie del conductor de alta tensión y partículas metálicas flotante en el gas.....	8
Figura 2.1. Circuito de medida de DP para el método convencional IEC 60270.	17
Figura 2.2. Circuito esquemático para ensayos y mediciones de DP en un transformador de potencia.	18
Figura 2.3. Sistema de medición todo acústico para detección de DP.....	21
Figura 2.4. Sistema de medición acústica con disparo eléctrico.....	22
Figura 2.5. Sistema de detección de DP con método de emisiones electromagnéticas utilizando una antena monopolo.....	23
Figura 2.6. Gráfica de la carga aparente q con respecto a la fase. Se muestra un patrón típico de DP interna generado por una cavidad esférica en un dieléctrico sólido de resina epóxica.	25
Figura 2.7. Cinco tipos de defectos generando DP de tipo interna (Gulski et al., 1990).	26

Figura 2.8. Distribuciones $H\eta(\varphi)$ y $Hq\eta(\varphi)$ para dos tipos defectos generando descargas internas. a) cavidad junto a un electrodo, b) múltiples cavidades, (Gulski et al., 1990)	27
Figura 2.9. Defectos simulados en un laboratorio para crear una base de referencia de DP, (Kreuger et al., 1993).....	28
Figura 2.10. Mapa de tiempo-frecuencia para DP internas y ruido (Albarracin, 2014).....	30
Figura 2.11. Análisis multiresolución para descomposición con la DWT (Sahoo et al., 2005)	32
Figura 2.12. Respuesta en frecuencia de filtros wavelet para $M=3$. El eje de frecuencia está normalizada a la unidad. (Gu et al., 2000).....	32
Figura 2.13. Extracción de características por medio de DWT. a) Señal acústica desde DP interna; b) Señal acústica desde DP superficial; c) Huellas DWT para DP interna y superficial.	34
Figura 2.14. Modelo geométrico espacial para la obtención de los TDOA.....	36
Figura 2.15. Obtención de los TDOA utilizando las señales medidas.....	37
Figura 2.16. Par de señales reales UHF con los puntos de llegada a los sensores señalizados.....	38
Figura 2.17. Par de Señales UHF normalizadas y obtención del primer pico de cada señal para la obtención de los TDOA, (Sinaga et al., 2012b).....	39
Figura 2.18. Gráfica de energía acumulada para un par de señales UHF, (Judd et al., 2005).	40
Figura 2.19. Parámetros del par de filtros estimados por el algoritmo BSS. Se muestra con una flecha roja el TDAO entre los dos sensores (Boya et al, 2015b).....	41
Figura 2.20. Ejemplo de los patrones PRPD. (a) DP superficial, (b) DP corona y (c) DP superficial y corona simultáneamente. El eje vertical representa la carga en pico coulombio y el eje horizontal, la fase (Cacciari et al., 1993).	43
Figura 2.21. Ejemplo de separación de dos tipos de DP utilizando el método de mapa tiempo-frecuencia. a) patrón PRPD sin procesar, b) Mapa tiempo-frecuencia utilizado para la separación, patrones PRPD para la c) fuente #1 y d) fuente #2; pulsos representativos para e) fuente #1 y f) fuente #2 (Cavallini et al., 2003).....	46
Figura 2.22. A) Patrón PRPD de DP en una barra Roebel de un generador síncrono con ruido eléctrico presente. b) Gráfica en tres dimensiones con los tres componentes principales de energía una vez realizado la descomposición Wavelet y Análisis de componentes principales, (Hao et al., 2010 y Hao et al., 2011).....	47

Figura 2.23. Patrones PRPD y sus señales representativas para tres clústeres en la Figura 27. a), c) y e) patrones PRPD del clúster #1, #2 y #3, respectivamente; b), d) y F) las señales relevantes representativas, (Hao et al., 2010 y Hao et al., 2011).....	48
Figura 2.24. Modelos de defectos para generar señales acústicas de DP. a) Electrodo punta-plano para DP tipo corona, b) Electrodo plano-plano con aislamiento para generar DP tipo superficiales, c) electrodos cilindro plano para generar DP tipo superficiales, (Kundu, et al., 2012).	50
Figura 2.25. Distribución de energía de las señales acústicas de DP. a) Electrodo punta-plano, b) Dos electrodos punta-plano activos simultáneamente, c) electrodos plano-plano con aislamiento, d) Dos electrodos plano-plano activos simultáneamente, e) Electrodo cilindro-plano con aislamiento, f) dos electrodos cilindro-plano activos simultáneamente, (Kundu, et al., 2012).....	50
Figura 2.26. Dimensión fractal vs lacunaridad para una sola fuente de DP corona activa con un modelo punta-plano (pntpln1) y dos fuentes de DP corona activas simultáneamente con un modelo punta plano (pntpln2), (Kundu, et al., 2012).	51
Figura 3.1. Tres personas conversando y siendo grabadas por tres micrófonos. Donde s_i son las fuentes y x_i las mezclas.	56
Figura 3.2. Diagrama de bloques de la operación para resolver el problema BSS.	58
Figura 3.3. Dos fuentes DP emitiendo ondas electromagnéticas. Se muestran las trayectorias de los frentes de onda. Los sensores captan copias distorsionadas de las emisiones debido al medio.	60
Figura 3.4. Modelo de mezclado convolutivo para las fuentes.....	62
Figura 3.5. Ejemplo de un filtro h_{12} para una estructura de mezclado convolutivo de dos fuentes y dos mezclas.	62
Figura 3.6. Proceso llevado a cabo por FastICA para la búsqueda de un componente independiente. Este ejemplo es para la búsqueda de un componente independiente dado tres mezclas.	69
Figura 3.7. Ejemplo de una PDF laplaciana de tipo supergaussiana. Éstas presentan la probabilidad concentrada en para algunos valores, lo que les da forma afilada. U.A. significa Unidades Arbitrarias....	72
Figura 3.8. PDF uniforme de tipo subgaussiana. En este ejemplo los valores en amplitud de -1 a 1 presentan igual probabilidad. Esto le da forma plana. U.A. significa Unidades Arbitrarias.	73
Figura 3.9. Modelo de estructura de separación y estimación de fuentes.....	80
Figura 4.1. Esquemas para generar DP: (a) Internas, y (b) Superficiales (Rubio-Serrano et al., 2012).	85
Figura 4.2. Se muestra las dos fuentes de DP: Superficial e Interna, el sensor de emisiones acústicas (EA) y el tanque con el aceite del transformador.	85

Figura 4.3. a) Ejemplo de una de las EA desde una fuente de DP interna, y b) su densidad de potencia espectral.....	86
Figura 4.4. a) Ejemplo de una de las EA desde una fuente de DP superficial, y b) su densidad de potencia espectral.....	87
Figura 4.5. Distribución promedio de energía por para cada nivel de descomposición Wavelet para cada grupo de 25 señales acústicas desde las fuentes DP internas y superficiales. La desviación estándar para cada nivel es mostrada en negro.	88
Figura 4.6. Vista de planta del tanque con aceite donde esta localizadas de las fuentes (interna y superficial) y los sensores para la simulación. Las fuentes están a 30 centímetros de la pared donde están montados los sensores ($d=30$) y separadas 10 centímetros una de otra ($l=10$).	89
Figura 4.7. Amplitud en Unidades Arbitrarias (U. A.). a) Señal acústica original desde la fuente DP interna s_1 , b) Señal acústica original desde la fuente DP superficial s_2	90
Figura 4.8. Filtros utilizados para crear las mezclas. Todos tienen una longitud $L = 11$	92
Figura 4.9. Amplitud en Unidades Arbitrarias (U. A.). a) Señal acústica medida en el sensor x_1 , b) Señal acústica medida en el sensor x_2	93
Figura 4.10. Estimaciones resultantes del algoritmo ICA-Amari. (a) Estimación y_1 y (b) estimación y_2	94
Figura 4.11. Huella de energía para las señales usadas en la simulación. a) señal en el sensor x_1 , b) señal en el sensor x_2 , c) señal estimada y_1 (DP interna), y d) señal estimada y_2 (DP superficial).	95
Figura 4.12. Esquema descriptivo del montaje del experimento. Los transductores ultrasónicos s_1 y s_2 y los sensores acústicos x_1 y x_2 están en el mismo plano horizontal; las medidas todas son en centímetros. Las coordenadas mostradas son un ejemplo y pueden ser cambiadas dependiendo de la necesidad.	96
Figura 4.13. Vista real de tanque, y las posiciones de los sensores de emisiones acústicas fijados a la pared externa del tanque y los transductores ultrasónicos.	97
Figura 4.14. Sistema de adquisición multicanal marca National Instruments, modelo PXI 5105. En su pantalla se muestran la forma de onda de los pulsos enviados a los transductores ultrasónicos y las señales acústicas medidas por los sensores de emisiones acústicas.	98
Figura 4.15. Generador de funciones arbitrarias marca RIGOL, modelo DG4162. Sus dos canales son conectados a cada transductor ultrasónico. En la pantalla se muestran los pulsos eléctricos enviados para excitar estos transductores.	99

Figura 4.16. (a) Huella generada por la señal emitida desde el transductor s_1 la cual es similar a la fuente de DP interna. (b) Huella generada por la señal emitida desde el transductor s_2 la cual es similar a la fuente de DP superficial.	100
Figura 4.17. (a) Señal acústica en el sensor x_1 , (b) señal acústica en el sensor x_2 , (c) y (d) señales estimadas y_1 y y_2 por el algoritmo ICA-Amari, respectivamente.....	102
Figura 4.18. Huella de energía para señales reales acústicas. (a) Mezcla real desde el sensor x_1 . (b) Mezcla real desde el sensor x_2 . (c) Señal estimada y_1 . (d) Señal estimada y_2	103
Figura 4.19. Distribuciones de las señales fuentes. Se han utilizado las 25 señales por cada tipo para generarlas. (a) Interna, (b) Superficial.....	103
Figura 4.20. a) Función de distribución laplaciana. b) Función de activación derivada de la función de distribución laplaciana. Como se puede observar es una función $\text{sign}()$ en donde para cualquier valor u mayor de cero resulta en +1 y para valores negativos de u , en -1.....	104
Figura 4.21. Efecto de la longitud de los filtros con respecto a la calidad de la separación. Se utiliza el coeficiente de correlación para evaluar el rendimiento y se compara para tres distintas tasas de aprendizaje. En esta grafica se compara la huella de energía de la estimación y_1 con la huella de energía de la fuente de DP interna s_1	106
Figura 4.22. Relación entre el número de iteraciones y el coeficiente de correlación para diferentes tasas de aprendizaje. En esta gráfica se compara la huella de energía de la estimación y_1 con la huella de energía de la fuente de DP interna s_1	107
Figura 4.23. Montaje experimental para generar mezclas desde múltiples fuentes de DP (vista de planta).	109
Figura 4.24. Filtros para la estimación de los TDOA entre los sensores x_1 y x_2 cuando solo está activa una fuente. En este caso la fuente de DP Interna s_1 . U.A: Unidades arbitrarias.....	110
Figura 4.25. Filtros para la estimación de los TDOA entre los sensores x_1 y x_3 cuando solo está activa una fuente. En este caso la fuente de DP Interna s_1 . U.A: Unidades arbitrarias.....	110
Figura 4.26. Filtros para la estimación de los TDOA entre los sensores x_1 y x_2 cuando las dos fuentes están activas. En w_{12} se muestra el TDOA τ_{21} que representa el retardo de s_2 en x_2 respecto a x_1 . En w_{21} se muestra el TDOA τ_{12} que representa el retardo de s_1 en x_1 respecto a x_2 . U.A: Unidades arbitrarias.....	111
Figura 5.1. Montaje del experimento para generación de emisiones electromagnéticas de dos fuentes de descarga superficial.	117

Figura 5.2. Antena monopolo utilizada para la detección de las señales UHF. Consiste en un conductor de cobre de 10 centímetros soldado al pin de metal del cable coaxial.	118
Figura 5.3. Posiciones de las fuentes y los sensores. Las coordenadas están en centímetros.	118
Figura 5.4. Ejemplo de las señales electromagnéticas generadas en el experimento. (a) Señal desde en objetivo de ensayo s_1 y (b) Señal desde el objeto de ensayo s_2	119
Figura 5.5. Distribución promedio de energía por para cada nivel de descomposición Wavelet para cada grupo de 100 señales electromagnéticas desde las fuentes superficiales s_1 y s_2 , respectivamente. La desviación estándar para cada nivel se muestra en negro y corresponde a 2% para cada fuente.....	120
Figura 5.6. Señales de ruido afectando las señales detectadas en las antenas.	121
Figura 5.7. Ejemplo de señales electromagnéticas registradas por los sensores y de las estimadas por el algoritmo ICA-Amari. (a) Señal en el sensor x_1 , (b) Señal en el sensor x_2 , (c) Señal y_1 estimada (d) Señal y_2 estimada.	123
Figura 5.8. Pesos $w_{12}(a)$ y $w_{12}(b)$ para la estimación de los TDOA. Se ha colocado una fleja roja para indicar la diferencia temporal desde la muestra inicial a la muestra con la máxima magnitud. Para el peso w_{12} la diferencia es de 17 muestras y para el peso w_{21} la diferencia es de 18 muestras.....	124

II. INDICE DE TABLAS

Tabla 2.1. Porcentaje de energía por nivel de descomposicion para DP internas y superficiales.....	34
Tabla 3.1. Lista de funciones para cálculo de la Negentropía. ξ representa el argumento de la función. ..	67
Tabla 3.2. Pasos del algoritmo FastICA.	69
Tabla 3.3. Funciones de densidad de probabilidad y sus funciones de activacion, respectivamente. El simbolo σ se refiera a la varianza de la señal.	77
Tabla 3.4. Algoritmo ICA-Amari.	78
Tabla 3.5. Algoritmo Amari para mezclado convolutivo.	81
Tabla 4.1. Rangos de frecuencias correspondientes a cada nivel de descomposición Wavelet.....	87
Tabla 4.2. Valores para los parámetros del algoritmo ICA-Amari para mezclas convolutivas	94
Tabla 4.3. Comparación entre las huellas Wavelet de las fuentes y las estimaciones.	95
Tabla 4.4. Parámetros para el algoritmo ICA-Amari para separación de dos fuentes.	101
Tabla 4.5. Condición de parada δ del algoritmo ICA-Amari, el número de iteraciones utilizadas y el coeficiente de correlación para esa cantidad de iteraciones. En este análisis se la compara la huella de energía de la estimación y_1 con la huella de energía de la fuente de DP interna s_1	107
Tabla 4.6. Posiciones de las fuentes (s_1 y s_2) y los sensores (x_1 , x_2 y x_3)	108
Tabla 4.7. Comparativa entre los métodos Amari, energía acumulada y correlación cruzada con una fuente activa (s_1).....	112
Tabla 4.8. Comparativa entre los métodos ICA, energía acumulada y correlación cruzada con dos fuentes activas (s_1 y s_2).....	112
Tabla 5.1. Descomposición Wavelet de la señal de DP superficial de la gráfica (a) Figura 69. Se ha colocado para cada nivel de energía el tipo de ruido que la afecta en la medición.....	121
Tabla 5.3. Parámetros para el algoritmo ICA-Amari para separación de dos fuentes.	122

CAPITULO 1

1. Introducción

Los equipos eléctricos, tales como: generadores, transformadores y conductores son vitales para mantener la calidad de vida de la sociedad actual. Estos equipos aportan un suministro continuo de energía eléctrica a los hogares, comercios e industrias. Su fiabilidad depende directamente del aislamiento eléctrico por lo que es importante monitorizar su estado continuamente.

El aislamiento provee una separación eléctrica entre conductores. Está constituido por materiales dieléctricos los cuales pueden soportar un intenso campo eléctrico antes de llegar a la condición de ruptura y convertirse en conductores. El valor del campo eléctrico para el cual se presenta esta ruptura se conoce como rigidez dieléctrica y se mide en voltio por metro (V/m). Cuando este valor es sobrepasado, el aislamiento pierde su propiedad dieléctrica generándose una falla; normalmente catastrófica para el equipo.

La rigidez dieléctrica puede verse reducida debido a defectos en el aislante desarrollados en su manufactura o en condiciones de operación. Existen muchos tipos de defectos y su naturaleza depende del tipo de aislamiento y su utilización. Ejemplo de ellos son: pequeñas protuberancias en las paredes metálicas de un transformador o de una Subestación Aisladas por Gas o GIS (Gas Insulation Switchgear) producto de fallas en la manufactura, polvo acumulado por contaminación sobre un aislante que no cubre totalmente un conductor, como en el caso de aisladores de porcelana en líneas eléctricas aéreas; o pequeñas cavidades embebidas en un aislante sólido de un cable de potencia.

La rigidez dieléctrica establece la máxima tensión que el aislante puede soportar antes de convertirse en conductor. Esta tensión es llamada tensión de ruptura. En condiciones normales de operación, los aislantes son sometidos a valores muy por debajo esta tensión para evitar un fallo en el equipo. Sin embargo, la presencia de defectos reduce la homogeneidad de las propiedades dieléctricas del aislante de tal forma que el campo eléctrico deja de ser uniforme y cambia localmente alrededor del defecto. Dependiendo de la composición química del defecto, el campo eléctrico puede aumentar localmente y, de esta manera, aunque se aplique al aislante una tensión menor a su tensión de ruptura,

existe la posibilidad que en la zona del defecto esta tensión sea suficiente para generar una descarga eléctrica. Estas descargas son conocidas como Descargas Parciales (DP) ya que su duración es muy corta (menor a un microsegundo) y no causan una ruptura total del aislante. Sin embargo, su repetida acción altera las propiedades dieléctricas y puede llevar a un fallo total.

Una vez que las descargas están presentes, aun si son intermitentes, el daño siempre se incrementa con el tiempo. Por ejemplo: la presencia de micro cavidades embebidas en un aislante sólido genera descargas; con el tiempo se producen picaduras en la superficie de las cavidades. Estas picaduras se convierten en pequeñas grietas las cuales se llenan de cristales formados por la descomposición química de los gases y del material dieléctrico. Eventualmente se forman arborescencias (defecto con ramificaciones) que son caminos conductivos para los electrones. Este proceso de deterioro puede propagarse y desarrollarse en una amplia zona del aislamiento, afectando su propiedad dieléctrica, convirtiéndolo en conductor y generando una falla en el equipo. Normalmente esta falla es repentina y catastrófica produciendo explosiones e incendios.

La detección y análisis de la actividad de las descargas se utiliza como una herramienta para la evaluación de la condición del aislante. De esta forma, se puede anticipar una falla y realizar operaciones de mantenimiento al equipo mejorando su confiabilidad en operación. Por esta razón, a través de los años, se ha invertido mucho tiempo en el estudio de las descargas y se han estableciendo varias líneas generales de investigación: naturaleza y proceso de generación, detección, identificación y localización de las descargas.

Esta tesis se enfoca en la identificación y localización las DP, proponiendo un nuevo método para tratar con más de una fuente de DP. Antes de entrar en los detalles de la propuesta se introduce una revisión del proceso de generación y detección de las DP.

1.1. Generación de las descargas parciales

Una DP es una descarga eléctrica de muy corta duración la cual se genera en un defecto sometido a una diferencia de potencial. Este defecto contiene o está rodeado de gas ([Van Brunt, 1991](#)). Ejemplos: cavidades muy pequeñas llenas de gas embebidas en un aislante sólido de un cable de potencia o burbujas rodeadas de aceite en un transformador. Cuando el equipo está en operación, la tensión que se aplica al aislante,

también se desarrolla localmente en estos defectos. Normalmente la rigidez dieléctrica del gas dentro defecto es menor que la rigidez del material aislante, de tal manera que la tensión de ruptura en el gas es menor. Aunque la tensión aplicada en el equipo tiene un valor muy por debajo que pueda ocasionar una falla al aislante, en el defecto, si se pueden presentar descargas debido a la menor rigidez y menor tensión de ruptura.

1.1.1. Mecanismo de generación

La tensión por sí sola no es el único factor desencadenante de las descargas. Es necesario la disponibilidad de electrones libres en el defecto, preferiblemente cerca del cátodo (zona del defecto polarizada negativamente). Dadas las condiciones de apropiadas de tensión estos electrones pueden iniciar un proceso de avalancha hacia el ánodo (zona del defecto polarizada positivamente) rompiendo la rigidez dieléctrica del gas y convirtiéndolo temporalmente en conductor. La emisión de electrones libres desde el cátodo es un proceso estocástico.

Existe un valor de tensión mínimo en el defecto que puede iniciar la descarga llamada tensión de ignición. Este valor depende varios factores: tipo de material dieléctrico que rodea el defecto, geometría, presión y temperatura de gas y la tensión aplicada.

La descarga genera una transferencia de carga eléctrica dentro del defecto y en el aislante. Si se colocan un equipo de detección apropiado este evento se puede observar como un pulso de corriente. En la **¡Error! No se encuentra el origen de la referencia.** se muestra un ejemplo de las señales asociadas a una descarga. Los pulsos de tensión y corriente se han exagerado para facilitar su visualización. Se asume que la tensión aplicada es alterna ($u_T(t)$) con un período de 20 milisegundos. Cuando $u_T(t)$ aumenta en la fase positiva aumenta la tensión $u_C(t)$ en el defecto. Cuando esta tensión alcanza el valor de ignición en la fase positiva ($+u_i(t)$) y existen suficientes electrones libres se inicia la descarga. Este evento genera una caída de tensión en la zona que rodea el defecto, liberando carga al aislante. Este movimiento de carga genera un pulso de corriente de una duración muy corta, menor a un microsegundo.

En la **¡Error! No se encuentra el origen de la referencia.** se dibujan y relacionan los pulsos de corriente a cada evento de DP. Es importante agregar que, si no hubiera electrones libres en el gas, aunque $u_C(t)$ sobrepasara el valor de ignición, las DP no se generarían. En la gráfica se han dibujado las curvas de la tensión en la cavidad $u_C(t)$ con DP y sin DP. Si se mantiene la tensión por encima del valor de ignición existe la

posibilidad de más eventos de descarga como se muestra en la Figura 1.1. Si la tensión aplicada disminuye por debajo de un valor, llamado tensión de extinción $u_e(t)$, las DP dejan de ocurrir. En la fase negativa de la onda, sucede una situación similar a la fase positiva, con la diferencia que los pulsos de corriente tienen polaridad invertida. Para las tensiones negativas existen los valores de tensión de ignición $-u_i(t)$ y tensión de extinción $-u_e(t)$.

La tensión de ignición de las DP puede ser determinada calculando el inicio temporal de los pulsos de corriente. En la práctica, para conocer este valor se modela un tipo de defecto y se le aplica una tensión por debajo del valor normal de ruptura y se eleva hasta que se observa una actividad sostenida de pulsos de corriente. Este valor es tomado como tensión de ignición para las condiciones específicas del ensayo.




Figura 1.1. Gráficas de las tensiones y corriente asociadas a un evento de DP. Se muestra la tensión variable aplicada $u_T(t)$, en este caso AC, al aislante. La tensión $u_c(t)$ en la cavidad cuando existen y no existen DP y los umbrales dados por los valores de la tensión de ignición, $u_i(t)$ y el valor de la tensión de extinción, $u_e(t)$, en las dos polaridades. También se muestra la serie de pulsos de corriente inducidos las DP.

1.1.2. Tipos de descargas parciales

Generalmente las descargas parciales se clasifican en tres tipos: internas, superficiales y corona. Estos tipos de descargas son generados por defectos con una composición específica entre el material aislante y los electrodos.

1.1.2.1. Descargas parciales internas

Estas DP ocurren en cavidades muy pequeñas llenas de gas y normalmente embebidas en un aislante sólido. En la Figura 1.2 se muestra una configuración física de estas cavidades, las cuales pueden estar adyacente a un electrodo o en medio de ellos. Las cavidades pueden tener distintas formas geométricas que van desde una forma esférica, elipsoidal, cubica o cilíndrica. Estos defectos se crean durante la fabricación del aislante debido a impurezas en el material, una mezcla imperfecta del material dieléctrico o una falla en el proceso de impregnación al vacío.

Los materiales aislantes sólidos que sufren las DP internas son de tipo polietileno, resina epóxica, papel impregnado de aceite, papel prensado con resina (pressboard) o mica. Estos son utilizados principalmente en cables de potencia, en los devanados de los transformadores o para aislar las barras de los motores y generadores. La presencia de este tipo de descarga es la más importante debido a que su actividad se presenta en puntos pequeños y débiles dentro del material aislante difíciles de monitorizar. Por esta razón la mayor parte la investigación sobre las DP está enfocada en este tipo de descarga.




Figura 1.2. Esquema representativo de varias cavidades generando DP internas. Las cavidades pueden encontrarse adyacentes a los electrodos o en medio de ellos.

1.1.2.2. Descargas parciales superficiales

Estas DP ocurren en una configuración en la cual el aislante está en medio de los electrodos, pero uno de estos sólo cubre una parte de aislante como se muestra en la Figura

1.3. En este caso se genera un campo eléctrico tangencial a la superficie del aislante que intensifica la tensión en el punto donde termina el electrodo e inicia la interfase entre el aislante y el gas. Estas condiciones pueden llevar al rompimiento de la rigidez de gas y generar las descargas.

Las DP superficiales se forman principalmente en los aisladores de cerámica, poliméricos y fibra de vidrio. Estos aisladores son utilizados en las líneas de potencia aérea o terminales de los transformadores por lo que están expuestos a la contaminación por el depósito de sales (en áreas costeras), arena, lluvia acida, carbón desde las industrias o escapes de los autos o fibras de celulosa. La contaminación forma una fina capa conductora encima del aislante. Si esta tiene contacto con el electrodo energizado extiende el potencial a lo largo de la superficie del aislador como especie de hilos conductores. Al terminarse abruptamente esta capa en algunas zonas del aislador, se intensifica el campo eléctrico a lo largo de su superficie y se forman las condiciones para la aparición de las DP superficiales. Con el tiempo van erosionando la capa aislante dejando el electrodo expuesto y con la posibilidad de una falla total. En la Figura 1.4 se muestra un plato de policarbonato afectado por descargas parciales superficiales. Se observan ramificaciones que se comportan como caminos conductivos a través de la superficie del aislante.




Figura 1.3. Esquema representativo para las DP tipo superficiales. En este tipo de DP el campo eléctrico es tangencial a la superficie del dieléctrico.



Figura 1.4. Un plato de policarbonato afectado por descargas parciales superficiales. Estas ramificaciones son como caminos conductivos a través de la superficie del aislante. Imagen obtenida desde: <https://commons.wikimedia.org/wiki/File:Tracking1.jpg>

1.1.2.3. Descargas parciales de tipo corona

Otra situación en la cuales se forman DP es debido a protrusiones en la superficie de los electrodos rodeados por gases o líquidos. Las protrusiones son pequeñas salientes en forma cónica, cilíndrica y esférica. En estos puntos el campo eléctrico se intensifica y aumenta la probabilidad de la rotura del dieléctrico que lo rodea. A este tipo de DP se les llama corona. En la Figura 1.5 se muestra un ejemplo de este tipo de descarga afectando los herrajes energizados de una línea de alta tensión. El efecto es la ionización del gas que rodea al conductor el cual genera un halo luminoso con forma parecida a una corona, de ahí el nombre de este tipo de descargas. En las GIS también puede aparecer este tipo de DP debido a protrusiones en el conductor de alta tensión. En el esquema de la Figura 1.6 se muestran protrusiones de dos tipos: tipo cilíndrica y tipo cónica. Este tipo de DP cambia afecta el gas SF₆ cambiando sus características aislantes al descomponerlo en otros tipos de gases. También, estas DP en contacto con aislante liquido como el aceite de los transformadores, puede producir burbujas las cuales generan DP internas.



Figura 1.5. Descargas parciales tipo corona alrededor de los herrajes del remate de una línea de alta tensión. Imagen obtenida desde: <http://www.coloradowireandcable.com/uncategorized/the-corona-discharge-its-properties-and-uses/>




Figura 1.6. Sección de la estructura metálica de una GIS. Se muestran las protuberancias en la superficie del conductor de alta tensión y partículas metálicas flotante en el gas.

1.2. Detección de las descargas parciales

El evento de una DP se manifiesta a través de la generación varias cantidades físicas, tales como: el desplazamiento de carga, generación de calor, reacciones químicas y emisiones electromagnéticas y acústicas. Para cada una de estas cantidades existen métodos de detección que se describen a continuación.

1.2.1. Detección eléctrica

Una descarga genera un desplazamiento de carga eléctrica que se detecta por medio de un apropiado circuito eléctrico. Si este circuito se conecta a un osciloscopio se observará un pulso de muy corta duración normalmente con un tiempo corto de subida y un tiempo de decaimiento más largo con algunas oscilaciones. Las características de este pulso, tales como: la forma su onda, amplitud o ancho se relacionan con el tipo material aislante, la geometría y presión de gas del defecto. De esta manera, la detección eléctrica de los pulsos ofrece información de las DP y el defecto que la genera. En la norma ([IEC-60270, 2000](#)) se describe el método de detección eléctrica conocido como el método convencional. Es el método de detección de DP más utilizado ya que ofrece el valor más cercano a la intensidad real de las DP.

1.2.2. Detección por medio de gases

La actividad de las DP genera diferentes tipos gases. Por ejemplo, las DP tipo corona expuesta al aire generan ozono. Si están localizadas en dentro de una GIS, estas DP pueden cambiar la composición de gas SF₆ creando gases basados en fluoruros y sulfuros y afectando la capacidad dieléctrica del aislamiento. En los transformadores, las DP generadas en burbujas, o por partículas o protrusiones producen hidrógeno, metano, etano y etileno. Si hay DP en los aislantes a base de celulosa, se genera monóxido y dióxido de carbono.

Dependiendo del medio dieléctrico se pueden aplicar diferentes métodos de detección, como el análisis del contenido de hidrógeno, análisis de gases disueltos en aceite o DGA (Dissolved Gas Analysis), análisis de ozono y cromatografía de gases para obtener la proporción de cada componente en el gas. Normalmente estos métodos son aplicados inicialmente cuando se sospecha de la presencia de DP, sin embargo, sólo puede dar pistas muy básicas ya que no tiene la capacidad de indicar la severidad de la actividad. El estándar [IEEE C57.104-2008](#) ofrece una guía para realizar mediciones de los gases generados por las DP en transformadores con aceite mineral.

1.2.3. Detección óptica

Los métodos de detección óptica se basan en la luz emitida por las DP. La intensidad de la luz y su longitud de onda depende de variables externas que afectan el aislante, tales como la presión y temperatura, así como del tipo de material dieléctrico. El espectro

óptico generado abarca desde el rango ultravioleta, pasando por el visible hasta el infrarrojo. Se pueden diferenciar dos técnicas de detección: La detección de DP en la superficie del equipo eléctrico y la detección de la señal óptica dentro del equipo. La primera es principalmente utilizada para la detección de DP tipo corona y superficiales. Como sensor, el ojo humano es el más barato y sencillo de utilizar. Sin embargo, está limitado una pequeña parte del espectro, por lo que se extiende su capacidad con el uso de cámaras de visión nocturna con más alta sensibilidad. Las DP corona generan una emisión que es difícil de detectar debido a la luz de sol, por que emplean cámaras ultravioletas. Por otro lado, se puede detectar la luz emitidas por las fuentes de DP dentro del equipo eléctrico como transformadores y GIS. En este caso se instala una fibra óptica dentro de la estructura metálica, la cual es utilizada como guía de onda para la luz para después realizar una detección y conversión optoelectrónica a través de fotomultiplicadores o fotodiodos.

Este método de detección solo se utiliza para evaluar la presencia de DP y no se utiliza para medir con precisión la carga desplazada por la DP ya que el medio de propagación afecta la señal óptica atenuándola y dispersándola.

1.2.4. Detección acústica

En el evento de una DP se libera una gran cantidad de energía en un intervalo muy corto de tiempo lo que produce cambios rápidos de temperatura en el gas que rodea el defecto, expandiéndolo y creando ondas mecánicas transitorias que son conocidas como emisiones acústicas (EA). Las EA se propagan desde su origen a una velocidad que depende de la geometría, la densidad y la elasticidad del medio. Con un apropiado sensor se pueden detectar estas emisiones, sin embargo, no es posible obtener información precisa de la cantidad de carga desplazada por la DP; aunque hay que destacar que, a diferencia de la detección eléctrica convencional, con la acústica es posible obtener información para la localización espacial de los defectos. En la especificación técnica [IEC-TS-62478](#) de la Comisión Electrotécnica Internacional o IEC (Siglas en inglés de International Electrotechnical Commission) se presenta el método de detección acústica que es considerado como un método no convencional para DP.

1.2.5. Detección electromagnética

Una DP emite radiación electromagnética debido al desplazamiento de cargas eléctricas en el sitio de la descarga. Esta radiación o emisión de energía electromagnética es propagada por una onda desde el sitio de descarga en varias direcciones, lo que estará influido por el patrón de radiación y las propiedades del medio. Debido a la corta duración de las DP la emisión electromagnética es transitoria y pulsada con un rápido tiempo de subida y un decaimiento con oscilaciones. Esta emisión es detectada por antenas en el rango de frecuencia UHF (Ultra High Frequency) que va de 300MHz a 3GHz. Tiene la desventaja, al igual que la detección acústica, no ofrecer información sobre la cantidad de carga, pero si sobre la localización de los defectos.

1.3. Objetivos de la tesis

Esta tesis doctoral se enfoca en identificación y localización de multiples DP utilizando los métodos de detección acústico y electromagnético. Estos métodos son llamados métodos de detección no convencionales y se aplican como una alternativa o complemento al método convencional. La tesis utiliza como guía la especificación técnica [IEC-TS-62478](#), la cual se presentan estos dos métodos no convencionales, describiendo el sistema de detección, sensores, ventajas y desventaja de cada método.

Un sistema de detección de DP basado en alguno de estos métodos está constituido por las etapas de detección, acondicionamiento y digitalización de la señal. Posteriormente se realiza su procesamiento cual tiene como objetivos principales identificar el tipo de DP y localizar el defecto que la genera.

Tradicionalmente en el proceso de detección se asume la presencia de una sola fuente de DP, de tal manera que los métodos de identificación y localización se enfocan en esta asunción. Cuando se realizan estas dos tareas, es necesario la utilización de un arreglo de sensores. En el caso de más de una fuente, las múltiples emisiones llegaran de igual manera a cada sensor. De esta forma, cada sensor registrará señales desde varias fuentes de descarga las cuales pueden llegar a mezclarse y cambiar su forma de onda llevando a una identificación incorrecta del tipo de DP. Para el caso de la localización se dificulta el cálculo de los tiempos de llegada o TDOA (Time Delay On Arrival).

La tesis doctoral tiene como objetivo principal proponer un método para identificar y localizar descargas en un ambiente con múltiples defectos utilizando Análisis de Componentes Independientes o ICA (Independent Component Analysis). ICA

hademostrado ser útil para revertir el proceso de mezclado y de esta forma recuperar la forma original de las señales emitidas. La tesis se centra en el método de detección acústico y el método UHF debido a que permiten monitorizar en línea, tienen una mejor respuesta frente al ruido que el método eléctrico y posibilitan la localización.

1.4. Estructura del documento

El documento se estructura de la siguiente manera: En el capítulo 1 se explica la naturaleza y generación de las DP, diferentes tipos DP y métodos de detección. Finalmente se presentan los objetivos de la tesis doctoral. En el capítulo 2 se presenta el estado del arte de la detección, identificación y localización. Se estudia y analiza el problema de la presencia de múltiples fuentes justificando la importancia y necesidad de la solución propuesta en la tesis.

A continuación, en el capítulo 3 se introducen los fundamentos de ICA explicando cómo se enfrenta el problema de mezclado y se llega a la separación de las señales originales. Se presenta y sustenta el algoritmo ICA utilizado en la tesis. En el capítulo 4 se aplica el algoritmo ICA en la separación de señales simuladas y generadas en un bando de ensayos. En este caso se utiliza el método de detección acústica. También se analizan los parámetros de operación, tales como: tasa de aprendizaje, longitud de los filtros y cantidad de iteraciones necesarias para obtener una óptima separación. En este capítulo se propone un método para la localización de múltiples fuentes de DP utilizando parámetros estimados por el algoritmo.

En el capítulo 5, ICA es propuesto para la identificación de señales detectadas por sensores UHF. Las señales son generadas en un laboratorio de alta tensión y estudiadas para reconocer sus características en tiempo y frecuencia. A las señales se les aplica un filtrado Wavelet y son procesadas por el algoritmo. Las señales son separadas e identificadas. En el capítulo 6, se presentan los aportes de la tesis y trabajo futuro además de las publicaciones asociadas a la tesis. Finalmente, en el capítulo 7 están las referencias utilizadas como sustento bibliográfico de la tesis.

CAPÍTULO 2

2. Detección, identificación y localización de DP

2.1. Introducción

Los defectos en el aislante generan DP que causan degradación al aislante eléctrico por lo que es importante mantener una evaluación constante de su actividad, ya que su intensificación nos puede dar evidencias de una inminente falla, normalmente catastrófica para el equipo y personal que lo opera. Por otro lado, la actividad de las DP no se mantiene constante en el tiempo y está asociada a un mecanismo de envejecimiento del aislante. Un defecto generando DP tipo corona puede presentar alta actividad y magnitud y no requerir una inmediata acción de mantenimiento ya que el deterioro causado al aislante es poco significativo. Normalmente sólo ioniza el gas que rodea el defecto, cambia sus propiedades, pero debido a que las descargas actúan sobre una gran área el gas se repone. Por otro lado, micro cavidades llenas de gas y embebidas en un aislante sólido generando una baja actividad de DP internas son un indicativo de un próximo evento de falla total de este aislante, lo que necesita una atención y corrección inmediata. En estos dos ejemplos, el defecto que genera DP de tipo corona y el que genera las DP internas no se encuentran en el mismo punto en el aislante. Diferenciar entre estos dos tipos de DP nos ofrece información sobre el lugar donde pueden estar localizados estos defectos.

Es necesario que los programas de mantenimiento y diagnóstico de equipos eléctricos incluyan procesos de detección, identificación y localización de DP. La detección nos permite obtener señales de las cuales se puede obtener información sobre la intensidad y el tipo de defecto. Un proceso de identificación se aplica para distinguir entre los diferentes tipos de descargas e incluso discriminar las señales que son ruido y que generan falsos positivos. Este proceso se caracteriza por reconocer patrones distintivos de cada tipo de descarga que posibilitan la clasificación de los defectos. Sin embargo, la detección e identificación puede ser insuficiente si el defecto no se localiza espacialmente. Esto es

muy evidente cuando se trata con equipos de gran tamaño o en subestaciones en las cuales hay gran cantidad de fuentes probables de DP.

En este capítulo presentaremos una revisión del estado del arte de los métodos de detección más importantes: eléctricos, acústico y electromagnético; así como los utilizados para la identificación y localización de las descargas. Al final analizaremos el problema de múltiples defectos generando DP y cómo afectan a estos métodos introduciendo una solución basada en Análisis de Componentes Independientes (ICA, siglas en inglés Independent Component Analysis).

2.2. Revisión histórica

Las primeras técnicas de detección consistían en utilizar rudimentarias antenas para captar los pulsos electromagnéticos de DP en los terminales de los transformadores, así como tubos metálicos colocados en sus paredes como guías de las ondas acústicas para escuchar los sonidos generados por la actividad. El tipo de descarga que era detectado era principalmente corona y superficial, ya que las internas eran muy difíciles de acceder con estos equipos. También se empleaban cámaras fotográficas en cuartos oscuros para captar DP tipo corona. Con el inicio de la tecnología electrónica, en 1933 se utilizaron oscilógrafos (primeros osciloscopios análogos con muy limitado ancho de banda) para detectar y distinguir visualmente los pulsos de DP. A principio de 1940, fue introducido el primer detector de pulsos de descargas, conocido como detectores de amplio ancho de pulso ([Austen et al., 1941](#)). En 1969 en ([Bartnikas et al., 1969](#)) se introdujo el analizador de pulsos multicanal, equipo que permitió relacionar la amplitud de los pulsos con respecto a la fase de la onda AC y de esta manera obtener patrones de distribución característicos de cada tipo de defecto útiles para la identificación de las DP. Desde principio de los noventa y gracias a los avances de la instrumentación electrónica no sólo se pudo adquirir con más resolución los pulsos y su amplitud, sino en su forma de onda. Como la forma de onda está relacionada con la naturaleza del defecto y su evolución en el tiempo, su adquisición permitió mejores patrones para el reconocimiento de las DP. También, en los noventa, se incrementó la investigación de las DP con propuestas basadas en el procesamiento de señales. Nuevas herramientas permitieron extraer e identificar información asociadas a las descargas, tales como análisis estadístico, Transformada Wavelet, Mapas de Tiempo-Frecuencia y Análisis de Componentes

Principales. Estos avances también posibilitaron la automatización del proceso de identificación y localización de las DP disminuyendo la intervención humana. En esta línea se presentaron diversos estudios utilizando redes neuronales artificiales, lógica difusa y desde principio de año 2000 máquinas de vector soporte vectorial. Además de los avances en instrumentación y procesamiento, se logró estandarizar varios métodos de detección a través de normas, tales como la IEC60270-2001 para la detección eléctrica de las DP, la IEEE Std C57.127TM-2007 para la detección y localización de emisiones acústicas desde las DP en transformadores con aceite, la IEEE Std 400.3TM-2006 para pruebas de DP en cables de potencia y la especificación técnica IEC-TS-62478 que trata los métodos de detección no convencionales acústicos y electromagnéticos.

En la actualidad, Las principales áreas de investigación en la actualidad son detección y localización de DP en equipos que funcionan con corriente directa, integración de nuevas técnicas para procesamiento de la señal con el objetivo de mejorar la relación señal a ruido y clasificación automática de las descargas, desarrollo de nuevos sensores enfocados en aumento de la sensibilidad y monitorización en línea de la actividad de DP para aplicaciones en campo.

2.3. Métodos de detección de descargas parciales

En esta sección se presentan los métodos de detección convencional eléctrico y los métodos no convencionales acústico y electromagnético. Estos últimos son los utilizados en la tesis doctoral.

2.3.1. Método eléctrico

En el método eléctrico convencional se detectan los pulsos de corrientes inducidos por el movimiento de carga en el aislante debido a un evento de DP. Este método esta estandarizado por la norma ([IEC-60270, 2000](#)). Para asegurar la reproducibilidad y comparación de las medidas de DP, en la norma IEC60270-2001 se recomienda el uso del circuito mostrado en la Figura 2.1, llamado circuito de detección indirecta. En la figura, la capacidad C_T representa al equipo al cual se le van hacer pruebas y es conocido como equipo bajo prueba u objeto de ensayo (ODE). El ODE es un modelo físico que simula un determinado defecto en los equipos eléctricos. Por ejemplo, el ODE puede ser

un arreglo de dos electrodos con un aislante sólido con micro cavidades embebidas, como una especie de emparedado, que simula una fuente de DP internas; o un electrodo cilíndrico con punta afilada y un aislante con una pequeña distancia entre ellos para simular DP tipo corona. C_K es una capacidad de acople que ofrece un lazo de baja impedancia al pulso de corriente de la descarga. Z_m es un inductor libre de DP que impide que los pulsos rápidos de corriente de las DP pasen a la fuente de tensión y que el ruido impulsivo de esta fuente afecte el circuito de medida. Con esto se logra que el pulso de corriente fluya hacia C_K conectado a la impedancia de medida Z_m . La fuente de alta tensión está compuesta por un transformador libre de interferencias, T_R . En pruebas de laboratorio, donde se usan arreglos básicos para la simulación de DP, T_R es un elemento aparte del ODE. Esto cambia cuando se realizan pruebas a un transformador o generador donde el embobinado está integrado al aislante y todo el equipo es el ODE.

La detección en el circuito indirecto funciona de la siguiente manera. Cuando ocurre un evento de descarga, en la capacidad C_T se da una caída de tensión. Para compensar esta caída, C_K libera una carga q por medio de una corriente $I(t)$ en un intervalo de tiempo $\Delta t = t_2 - t_1$ igual a

$$q = \int_{t_1}^{t_2} I(t) \quad (2.1)$$

La carga q está relacionada con la carga liberada q_C por la descarga por medio de la ecuación, ([Lemke et al., 2008](#));

$$q = q_C (C_b / C_C) \quad (2.2)$$

Donde C_b es la capacidad entre los electrodos y el defecto; y C_C la capacidad dentro del mismo defecto. Estas dos capacidades son muy difíciles de calcular sin embargo por experiencia se conocen que la relación entre las capacidades C_b y C_C es menor a la unidad, $(C_b/C_C) \ll 1$, indicando que la carga q es una fracción de la carga q_C . De esta forma, detectando la corriente $I(t)$ e integrándola se puede tener una cantidad proporcional de la carga q_C desplazada por la DP. La carga q es llamada carga aparente, por esta razón y su medida es el picoculombios, pC.

La impedancia Z_m es un filtro pasabanda RLC con un ancho de banda que dependerá de la resolución temporal requerida, la cual típicamente esta entre 5μ a 20μ . La norma IEC 60270 recomienda los siguientes valores en frecuencia para los equipos de medida:

$$\begin{aligned}
 30\text{kHz} &\leq f_1 \leq 100\text{kHz}; \\
 f_2 &\leq 500\text{kHz}; \\
 100\text{kHz} &\leq \Delta f \leq 400\text{kHz}.
 \end{aligned}$$

Donde f_1 y f_2 son los límites inferior y superior en frecuencia a -6 dB de la máxima ganancia, y Δf en ancho de banda.

La señal resultante de la impedancia Z_m es un pulso de tensión relacionado directamente al pulso de corriente $I(t)$ en el circuito de detección. Debido a su bajo valor, esta señal es amplificada, y posteriormente digitalizada.




Figura 2.1. Circuito de medida de DP para el método convencional IEC 60270.

En la Figura 2.2 se muestra un ejemplo de un circuito esquemático para medida eléctrica convencional con circuito indirecto para transformadores de potencia. Este arreglo permite utilizar, como capacitor de acople C_K , la capacidad interna del terminal, accesible por medio del derivador de tensión del transformador o bushing tap. Cuando esta prueba se realiza en transformadores de gran potencia se utiliza una tensión con una frecuencia del tercer armónico (150Hz o 180 Hz, dependiendo de la zona geográfica). Esta frecuencia permite aplicar varios niveles de tensión sin saturar el núcleo y así evitar daños al transformador.




Figura 2.2. Circuito esquemático para ensayos y mediciones de DP en un transformador de potencia.

En la norma IEC60270-2001 también se recomienda otro circuito donde la impedancia de medida Z_m está en serie con el objeto de ensayo C_T , el cual es llamado directo. Este circuito presenta más sensibilidad que el indirecto, sin embargo, en caso de fallo del aislante queda expuesta la tensión aplicada, poniendo en riesgo al equipo de medida y a los operarios. Por esta razón, el circuito indirecto es comúnmente más empleado por presentar un menor riesgo operativo.

Las señales obtenidas con el método de detección eléctrico son afectadas por el ruido eléctrico principalmente el inducido por fuentes electromagnéticas. Por tal razón el uso de este método está limitado a fábricas o laboratorios en los cuales se pueden realizar ensayos controlados. Por otro lado, la información obtenida de los pulsos no permite la localización espacial de las descargas lo que es una ventaja en los siguientes métodos que se presentaran.

2.3.2. Método acústico

Una descarga libera una gran cantidad de energía en un intervalo muy corto de tiempo lo que produce cambios rápidos de temperatura en el gas del defecto, expandiéndolo y creando ondas mecánicas transitorias o Emisiones Acústicas (EA) las cuales se propagan a una velocidad que depende de la geometría, la densidad y la elasticidad del medio.

En los equipos eléctricos las EA se propagan por diferentes tipos de medios, como sólido/gas, en el caso de una descarga corona generada por un electrodo afilado rodeado de aire; o sólidos/líquido/sólido en el caso de una descarga interna generada por cavidades dentro del devanado de un transformador y medida por sensores de EA en las paredes

metálicas de este equipo. En cada medio la señal acústica tiene una velocidad característica, así como diferente dispersión por lo que en cada punto la forma de onda de la señal puede diferir a pesar de ser generada por la misma fuente. Esta situación hace que la escogencia del tipo de sensor de EA y la ubicación del punto de medida, los factores más importantes en este método de medida.

El objetivo del sensor de EA es convertir los cambios de presión inducidos por las ondas acústicas en una de tensión eléctrica. Como los sensores no tienen características ideales y son influidos por el ruido circundante, se tienen que estudiar las condiciones de la aplicación. Ejemplo, si sólo se desea medir el valor máximo de las EA generadas por las DP es necesario que el sensor sea resonante a una banda estrecha de frecuencia donde sea conocido en base a la experiencia que está la mayor parte de energía de la DP. Esto también ofrece la ventaja de limitar el ruido en la señal detectada. Sin embargo, si es necesario localizar o identificar con características obtenidas de la forma de onda, se deben utilizar sensores con una respuesta amplia y plana en frecuencia. Estos permiten obtener toda la forma de onda de la emisión y así determinar características como tiempo de inicio de la señal, espectro y tiempo de subida. Su desventaja es que al aumentar el ancho de banda también se registra más ruido.

Hay varios tipos de sensores EA con respecto al medio donde son colocados. Para la detección en un medio gaseoso como el aire o gas SF₆ se utilizan micrófonos direccionales. Estos producen una tensión proporcional a la presión de la EA con respuestas en frecuencia de hasta 50kHz. En el caso de un medio líquido son utilizados hidrófonos, construido con materiales piezoeléctricos (PZT o Titanio-Zirconato-Plomo) con respuestas en frecuencia de hasta de 2MHz. También son empleados en líquidos, transductores optoacústicos basados en fibra óptica. En este caso se utiliza interferometría óptica y una parte de la fibra óptica como el elemento de medida.

La introducción de sensores como los hidrófonos o fibra óptica en un equipo es una forma invasiva de detección. Para realizar una detección no invasiva se pueden instalar sensores en las partes externas de los equipos. Este es el caso de los sensores de EA instalados en las paredes metálicas de un transformador o GIS. Estos sensores detectan en el rango ultrasónico de la emisión con frecuencias desde 30 kHz hasta 2 MHz. Son empleados en dos modos de respuesta en frecuencia: resonantes y de respuesta plana. Su construcción es basada en cristales piezoeléctricos. Estos transductores pueden responder a fuentes de ruido provenientes de emisiones electromagnéticas normalmente encontradas en subestaciones. Para minimizar este efecto, se utiliza dos tipos de montajes: diferencial,

el cual utiliza dos cristales montados fuera de fase para reducir el ruido o un solo cristal con blindaje a tierra con un circuito preamplificador integrado. Este es el tipo de sensor de EA que se utiliza en los experimentos descritos en esta tesis.

El método de detección de acústico se describe en la especificación técnica IEC-TS-62478 abarcando los sensores y su colocación para la detección, ensayos en laboratorio y en campo y localización en generadores, motores, transformadores, GIS y cables eléctricos. Por otro lado, también se ha desarrollado el estándar ([IEEE Std C57.127™, 2007](#)) para realizar detección acústica de DP, específicamente para transformadores con aceite. En este estándar se presentan dos métodos: El sistema todo acústico y sistemas acústicos con disparo eléctrico por DP.

Los sistemas todo acústico, consiste en la instalación de uno o varios sensores de EA en la pared externa del transformador. Cuando se utilizan varios sensores, además de la detección se posibilita la localización de la fuente de DP por medio de los tiempos de llegada de la onda acústica a cada sensor. Para localización espacial es necesario utilizar cuatro o más sensores. En la Figura 2.3 se puede observar el sistema todo acústico formado por un arreglo de cuatro sensores montados en las paredes del transformador. Después de medida, las señales son amplificadas, digitalizadas, almacenadas y procesadas.

Entre las ventajas de utilizar el método acústico se pueden mencionar: Bajo costo, fácil instalación, no es un método invasivo e tiene inmunidad frente al ruido electromagnético. Esta última ventaja es aprovechada para la detección en campo. Sin embargo, tiene la desventaja que, debido a que la señal acústica desde las fuentes de DP sufre atenuación y dispersión, la sensibilidad es muy baja y afectada por el ruido de fuentes acústicas que no son de DP. También, que el método es muy dependiente de la distancia entre las fuentes de DP y el punto donde están colocados los sensores. Estas desventajas no permiten relacionar directamente cuantificar la carga de las DP con las señales obtenidas en los sensores.

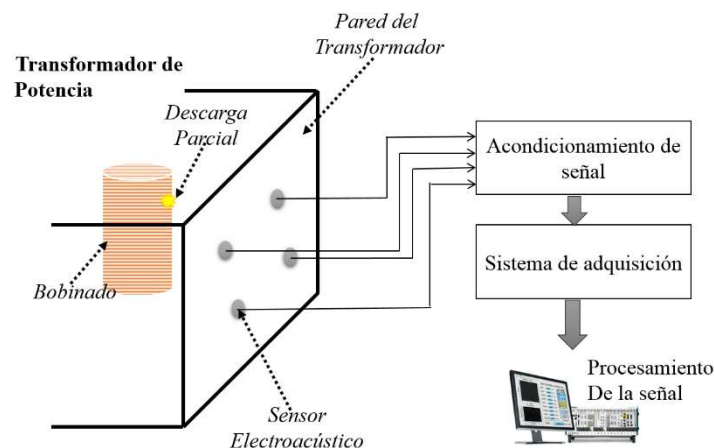


Figura 2.3. Sistema de medición todo acústico para detección de DP.

El sistema acústico puede ser integrado al método de detección convencional descrito en la norma IEC60270. En la Figura 2.4 se muestra un esquema de este sistema. Se utiliza un arreglo de sensores fijados al tanque del transformador que miden las señales acústicas junto a un sistema de medición eléctrica conectado al *derivador de tensión* y al aterrizaje del transformador. La fuente de tensión se instala en el devanado de baja tensión del transformador con una frecuencia típica de 180 Hz. La señal eléctrica inducida por la DP es medida en la impedancia Z . Dado que esta señal tiene una duración muy corta con respecto a la acústica puede ser utilizada como referencia o punto de origen para comparar con el tiempo de llegada a cada sensor de la onda acústica. En este caso para la localización de la fuente se utiliza el tiempo absoluto de llegada a cada sensor como base para su estimación. Esto facilita la operación de localización con respecto al todo acústico y disminuye a tres sensores de EA esta operación. Este tipo de sistema combinado tiene las mismas desventajas que el método convencional. Es muy susceptible al ruido eléctrico en el campo, por lo cual es sólo preferible para uso en lugares donde sea posible controlar el ruido externo como en fábricas o plantas de ensamblajes.




Figura 2.4. Sistema de medición acústica con disparo eléctrico.

2.3.3. Método electromagnético

Una DP emite radiación electromagnética debido al desplazamiento de cargas eléctricas en el sitio de la descarga. Esta radiación o emisión de energía electromagnética es propagada por una onda electromagnética desde el sitio de descarga a todas direcciones, lo que estará influido por el patrón de radiación y las propiedades del medio. Debido a la corta duración de los tiempos de subida de las ondas emitidas (menor a un nanosegundo), estas presentan un espectro desde los 3 MHz hasta los 3 GHz. La propagación de la velocidad es muy dependiente del tipo de dieléctrico, y normalmente esta por los 2×10^8 m/s ([IEC-TS-62478, 2016](#)).

En la detección electromagnética se trabaja en tres rangos de frecuencia: High Frequency (HF), que va desde los 3 MHz hasta los 30 MHz; VHF (Very High Frequency), desde los 30 MHz hasta los 300 MHz; y UHF (Ultra High Frequency), desde los 300 MHz hasta los 3 GHz. El primer rango, HF, se utiliza para detección de banda angosta o narrow band y el segundo VHF para detección de banda ancha o wide band, típicamente por encima de los 50 MHz. En el rango UHF se utiliza con técnica de barrido con un ancho limitado entre 3 MHz a 6 MHz o detección de banda ancha.

Como ejemplo de sensores para los rangos HF y VHF están: sensores de tipo capacitivo, transformadores de corriente, bobinas Rogowski, acopladores direccionales, acopladores de tipo disco y Transient Earth Voltaje (TEV). Para el caso UHF: Sensores de disco o cónicos, guía de onda, acopladores direccionales y antenas UHF.

En esta tesis doctoral se trabaja con antenas UHF. Una de las razones, es que en este rango se evita la interferencia por parte de emisiones con alta energía como las de radio

FM y AM las cuales están por debajo de los 300MHz. En la banda UHF las DP emiten suficiente energía como para ser apropiadamente detectadas ([Shibuya et al, 2010](#)) y ([Albarracin, 2014](#)).

Existen varios tipos de antenas UHF que son utilizadas para detectar DP en equipos, principalmente en transformadores, GIS y subestaciones aisladas por aire. Para transformadores y GIS las antenas más utilizadas son el acople tipo disco. Esta técnica para la detección en GIS y transformadores se basa en construir pequeñas aberturas en las paredes y colocar un disco metálico que funciona como antena UHF para detectar las DP ([Judd, 2001](#)).

Para realizar detección en subestaciones se utilizan antenas de hilo y antenas disco cono. Las antenas de hilo se clasifican en dipolos, monopolos, zigzag, lazos, tanto circular como cuadrado, y helicoidales. En la Figura 2.5 se muestra un sistema de medición utilizando antenas tipo monopolo para detección de DP superficiales en las terminales externas de un transformador de potencia. Consta de un alambre recto de cobre conectado al cable coaxial con un plano de tierra. Estas antenas son muy baratas y fáciles de construir además de ser omnidireccionales y una respuesta que depende del diámetro y longitud del alambre. Una vez detectada la señal ésta es amplificada, digitalizada y procesada para su visualización, análisis y almacenamiento.

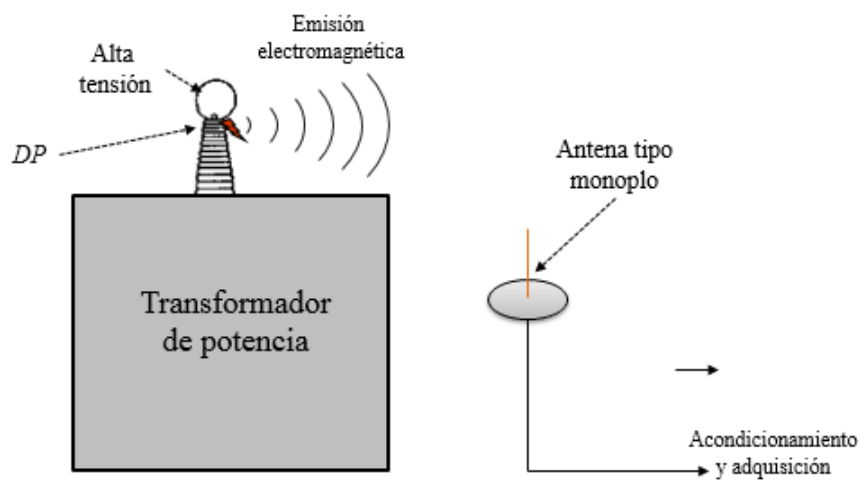


Figura 2.5. Sistema de detección de DP con método de emisiones electromagnéticas utilizando una antena monopolo.

La sencillez del método de emisiones electromagnéticas, además de los bajos costos lo hace muy apreciable para la detección en campo. Sin embargo, en el rango UHF, existe muchas fuentes de ruido que pueden interferir en la señal medida, tales como GSM, UMTS, WiFi y Televisión y radio digital. Además, DP tipo corona, arcos por cierre y

apertura de equipos en subestaciones y señales impulsivas desde sistemas electrónicos de control también pueden distorsionar las señales UHF. Es necesario, posterior a la etapa de detección, aplicar a la señal un procesamiento que disminuya estas interferencias.

Las ventajas principales de la detección electromagnética es que tiene mayor inmunidad frente al ruido que el método convencional y ofrece información para la localización espacial de los defectos. Sin embargo, con las señales detectadas no es posible cuantificar la carga desplazada por las DP. Además, debido a las altas frecuencias de las señales, los equipos para la digitalización son más costosos que en los métodos eléctricos y acústicos, así como más complejo el procesamiento.

2.4. Identificación de las descargas parciales.

En este apartado se presentan los métodos más importantes de identificación para las descargas.

2.4.1. Patrones de fase resuelta (PRPD).

Uno de los primeros métodos utilizados para la identificación de las descargas y que sigue en uso hoy en día, es basado en patrones que se van formando al relacionar la carga con respecto a la fase de la red eléctrica con el defecto que la genera. Se les conoce como patrones de fase resuelta (PRPD, siglas en inglés de Phase Resolved Partial Discharge). Los PRPD son formados por el ángulo de fase φ del valor de la carga aparente q de cada pulso de descarga. Estas magnitudes son obtenidas con el método convencional eléctrico. Los PRPD también se pueden generar con el método acústico y electromagnéticos sustituyendo el valor de carga aparente en pico coulombio por la amplitud de la señal en mili voltios. Sin embargo, no es posible relacionar el valor de la carga eléctrica con el valor de la señal de tensión obtenida con método acústico o electromagnéticos. En estos dos métodos la amplitud de la señal depende de la distancia y del medio, que puede diferir en cada ensayo ([Cavallini et al., 2011b](#)). No obstante, sirven para obtener información a partir de los patrones observados para cada defecto.

En el método PRPD es necesario fijar un umbral de valor de carga aparente q . Este umbral tiene como objetivo descartar señales con valor despreciable que normalmente son ruido. Por otro lado, este método solo se requiere un ancho de banda máximo de 500

kHz. Cada vez que ocurre una descarga que sobrepasa el umbral, se registra el valor de la carga y fase del pulso con respecto a la onda AC de la red eléctrica. El valor de la carga y la fase forman un par de coordenadas que son desplegados en la pantalla del osciloscopio. Es necesario medir varios ciclos de la onda sinodal para obtener un patrón distintivo a cada tipo de defecto. En la Figura 2.6 se muestra una gráfica de un patrón PRPD junto con la onda de tensión AC, el valor de carga aparente y el ángulo de fase de cada valor de descarga. Este patrón PRPD es un patrón típico de un defecto de tipo cavidad esférica en un aislante sólido de resina epóxica generando DP internas. De esta manera, al obtener los PRPD de diferentes tipos de DP se puede realizar una identificación del defecto que las causa.




Figura 2.6. Gráfica de la carga aparente q con respecto a la fase. Se muestra un patrón típico de DP interna generado por una cavidad esférica en un dieléctrico sólido de resina epóxica.

Antes de la proliferación de las computadoras, la identificación de un defecto por medio de su PRPD se llevaba a cabo con la ayuda de un experto. El experto observaba los PRDP en la pantalla de un osciloscopio y evaluaba de que tipo defecto provenía. Basado en esta información y en base a su experiencia, se evaluaba el nivel de peligrosidad de la actividad de las descargas. Con la introducción de las computadoras los PRPD además de ser desplegados y almacenados, se les pueden aplicar algoritmos basados en estadísticos y procesamiento de señales que realizan la identificación automáticamente.

Los patrones PRPD normalmente son visualizados en gráficas de dos y tres dimensiones. Para la gráfica de tres dimensiones es integrada otra variable más, η , que es el número de descargas por fase. Para obtener esta última variable es necesario registrar

varios ciclos de red. De las tres variables φ, q, η del patrón PRPD se derivan distribuciones estadísticas que ofrecen más información sobre la actividad de descargas de un defecto:

$H_{qmax}(\varphi)$ que es la distribución del máximo valor de carga por fase.

$H_{\eta}(\varphi)$, distribución del número de descargas por fase y

$H_{q\eta}(\varphi)$, la media de la descarga por fase.

Los trabajos de ([Tanaka et al., 1978](#)) y ([Gulski et al., 1990](#)) son pioneros en la utilización de análisis estadístico utilizando estas distribuciones con el objetivo de identificar defectos. Tanaka y Okamoto utilizaron momentos estadísticos tales como la asimetría y la curtosis para caracterizar estas distribuciones. En el trabajo de Gulski se propuso la creación de una base de datos de defectos. Para crear la base de datos se diseñó un experimento para simular varios tipos de descargas a partir de diferentes defectos. Ejemplo: objetos de ensayo modelando cinco tipos de defectos que generaban DP internas. En la Figura 2.7 se muestran estos modelos: cavidad con arborescencia (cavity with treeing), cavidad plana (flat cavity), cavidad estrecha (narrow cavity), cavidad junto a un electrodo (electrode-bounded cavity) y múltiples cavidades (multiple cavity). Las DP fueron medidas durante 20 minutos de la tensión de red de tal manera que se creaban patrones bien claros de cada defecto. De los PRPD se calculaban las distribuciones $H_{\eta}(\varphi)$ y $H_{q\eta}(\varphi)$. En la Figura 2.8 se muestran estas distribuciones para defectos tipo cavidad junto a un electrodo y múltiples cavidades, respectivamente. Las distribuciones varían para cada defecto y para cada mitad del ciclo de red (de 0-179° y (180 a 360°).




Figura 2.7. Cinco tipos de defectos generando DP de tipo interna ([Gulski et al., 1990](#)).

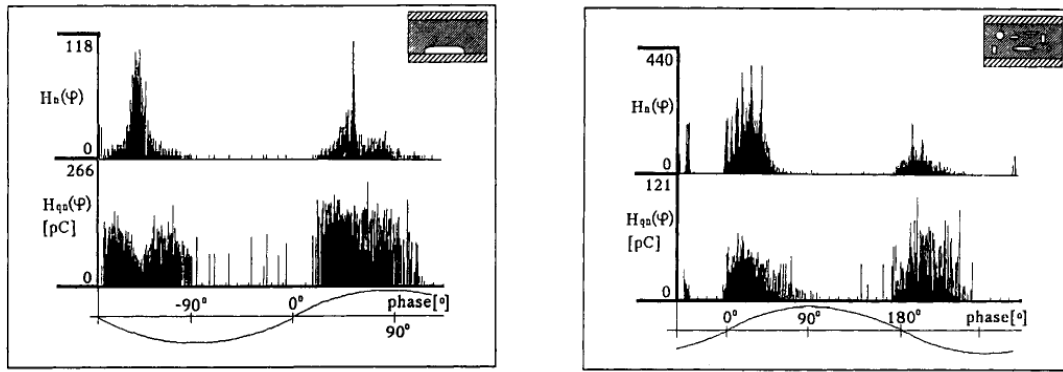


Figura 2.8. Distribuciones $H_{\eta}(\varphi)$ y $H_{q\eta}(\varphi)$ para dos tipos defectos generando descargas internas. a) cavidad junto a un electrodo, b) múltiples cavidades. [\(Gulski et al., 1990\)](#)

Las diferencias en las distribuciones entre los defectos posibilitaron la creación de patrones distintivos a partir de descriptores estadísticos, tales como: la media, la varianza, la asimetría y la curtosis de la parte positiva y negativa de las distribuciones, y el coeficiente de correlación entre la forma de la distribución de la mitad positiva con respecto a la mitad negativa. Con estos patrones basado en descriptores estadísticos se creó una base de datos referencial para cada defecto.

En posteriores trabajos de [\(Gulski et al., 1992\)](#) y [\(Gulski et al., 1993\)](#) se analizó el cambio de las distribuciones $H_{\eta}(\varphi)$ y $H_{q\eta}(\varphi)$ en el tiempo para evaluar como el envejecimiento afecta a las distribuciones y se propone la automatización por medio de redes neuronales del proceso de identificación, respectivamente. Otro trabajo pionero a destacar [\(Kreuger et al., 1993\)](#), en el cual se introducen las redes neuronales con el objetivo de automatizar la operación de identificación. Esta investigación se realizan un experimento donde se simulan trece modelos de defectos generando DP de tipo interna, superficial, corona, arborescencia y de partículas metálicas flotantes. En la Figura 2.9 se muestran ocho ejemplos de defectos utilizados en el trabajo. Cuatro defectos en un aislante para DP de tipo interna: cavidad plana (FLAT-DIEL), cavidad cuadrada (SQUARE-DIEL), cavidad estrecha (SHARP-DIEL) y cavidad plana junto a un electrodo (FLAT-COND). Un defecto para generar DP de tipo superficial en aire, aceite o SF6. Un defecto para DP tipo corona en aire y aceite. Un defecto tipo arborescencia en un aislante sólido (TREEING) y un defecto para generar DP debido a partículas flotantes en aceite (FLOATING PART). Los defectos fueron utilizados para generar una base de datos de referencia utilizando características tales como la asimetría, curtosis y correlación entre la parte positiva y negativa de las distribuciones $H_{\eta}(\varphi)$ y $H_{q\eta}(\varphi)$. Esta base de datos fue utilizada para identificar defectos desconocidos en transformadores, cables y GIS.




Figura 2.9. Defectos simulados en un laboratorio para crear una base de referencia de DP, ([Kreuger et al., 1993](#)).

Además de las redes neuronales se han propuestos otros algoritmos para automatizar el proceso de identificación, tales como: mapas auto organizados ([Guslki et al., 1993](#)), clasificadores de distancia ([Krivda, 1995](#)), modelos escondidos de Markov ([Abdel-Galil et al., 2004](#)), lógica difusa ([Contin et al., 2002](#), [Rizzi et al., 2009](#)) y máquinas de vectores soporte ([Sharkawy et al., 2007](#), [Hao et al., 2010](#))

2.4.2. Tiempo resuelto.

Los patrones PRPD no son apropiados cuando no hay referencia de fase como en el caso de sistemas que funcionan con corriente directa o HVDC (High Voltage Direct Current). Además, los patrones PRPD no ofrecen la forma de onda de la descarga ya que la resolución es muy baja con un ancho de banda limitado a 500kHz y el PRPD está enfocado sólo la obtención del valor de carga y la fase.

La forma de onda de las PD ofrece información que puede ser relacionada con el defecto, incluso en cómo evoluciona en el tiempo ([Morshuis, 1993](#)). Cuando se realiza una identificación basada en la forma de onda de las DP se le conoce como identificación por tiempo resuelto.

Cuando se utilizan el método convencional y el electromagnético, las señales de las descargas, normalmente, tiene una duración de unos pocos nanosegundos. Es necesario que en la digitalización de la señal se utilicen tasas de muestreo que estén por encima de 1 GHz y de esta manera conseguir una resolución que permita observar los detalles de la forma de onda. Para el caso del método de detección acústico, donde se detectan ondas

mecánicas que son mucho más lentas que la eléctrica y electromagnética, es suficiente con tasas de muestreo por encima de un 1 MHz.

La forma del pulso depende del tipo de defecto y su evolución en el tiempo ([Morshuis, 1993](#), [Contin et al., 2002](#), [Cavallini et al., 2003](#), [Contin et al., 2009](#)). El mecanismo físico de generación de DP en el defecto afecta las características de la forma de onda. Se puede obtener información sobre el estado del aislante analizando características tales como: tiempo de subida, el cual es el tiempo que toma de subir desde el 10% al 90% del valor pico del pulso; tiempo de bajada, el cual es el tiempo que se toma de bajar desde el 90% al 10% del valor pico del pulso; y ancho del pulso, que es el intervalo de tiempo entre el 50% desde ambos lados del valor pico. Estas características del pulso desde el dominio del tiempo son distintivas para cada defecto.

Al utilizar la forma del pulso para obtener información sobre los defectos es importante tener en cuenta que su forma real puede ser modificada por las propiedades del medio donde la onda se propaga. La geometría de la propagación, la temperatura, cambios en el tipo de medio, las reflexiones y el ruido pueden distorsionar la forma del pulso antes de llegar al sensor. Esta forma de onda también puede ser alterada por el sensor que es utilizado para su medida. Si el sensor tiene un ancho de banda menor que el contenido espectral del pulso puede atenuar algunas bandas de frecuencia añadiendo oscilaciones a su forma de onda que no son parte real del pulso.

Uno de los métodos para identificación más importantes utilizando información desde la forma de onda fue propuesto en ([Contin et al., 2002](#)) donde, a partir de descriptores basados en tiempo y frecuencia, se genera un mapa de dos dimensiones en los cuales pueden obtenerse patrones característicos de cada tipo de defecto. El método consiste en extraer un valor representativo del ancho de onda de cada pulso de descarga en el dominio del tiempo σ_T y un valor equivalente de ancho de la onda en el dominio de la frecuencia σ_F . Las variables σ_T y σ_F funcionan como dos coordenadas en un mapa de dos dimensiones llamado mapa Tiempo-Frecuencia o T^2W^2 . La ventaja de este método es que simplifica una cantidad de muestras en sólo dos valores por cada evento detectado. En la Figura 2.10 se muestra un ejemplo de un mapa T^2W^2 utilizando señales desde DP internas. Cada punto, rojo o azul, representa un evento y está localizado en el mapa como coordenadas σ_T y σ_F . En este ejemplo, los pulsos de descarga con similares formas de onda en términos de σ_T y σ_F son agrupados juntos, por lo que se crean clústeres muy bien definidos; uno con puntos de color rojos y que provienen de señales de ruido y el otro, formado de puntos en azules, desde las señales de DP internas. Los pulsos de las DP

internas forman un grupo que se va apilando hacia la esquina inferior derecha del plano; en cambio, los valores del ruido forman dos agrupaciones a la izquierda del mapa. Con el mapa T^2W^2 se puede diferenciar entre las señales de ruido y las provenientes de una DP interna con gran facilidad.




Figura 2.10. Mapa de tiempo-frecuencia para DP internas y ruido (Albarracin, 2014)

En (Cavallini et al., 2003) se utilizan los mapas T^2W^2 y un clasificador de lógica difusa para identificar descargas internas, superficiales y corona, además de diferenciar los pulsos de DP del ruido enfocados en transformadores de potencia y de corriente, motores de inducción, generadores y cables de potencia.

Otro método para identificación de DP se basa en la transformada Wavelet. Con este método se extraer información en tiempo y frecuencia en detalle de la onda de tal forma lo que posibilita la creación de patrones para cada tipo de DP. La transformada Wavelet continua (CWT, Continuous Wavelet Transform) es una medida de la similitud entre una señal y un conjunto de funciones temporales especiales (con una característica oscilante y rápidamente amortiguada) llamadas wavelets. Cada wavelet del conjunto se construye por la comprensión o dilatación y por la traslación de una función original llamada wavelet madre. La CWT de una señal $x(t)$ con respecto a su wavelet madre $\psi(t)$ se define como (Sahoo et al., 2005):

$$\text{CWT}(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt, \quad a > 0 \quad (2.3)$$

donde a es la dilatación o factor de escala y b es el factor de traslación, y ambas variables son continuas. $CWT(a, b)$ son llamados coeficientes wavelets. Esta transformada ofrece información continua sobre la señal estudiada, sin embargo, en muchos casos es más efectivo cuantificar esta información y hacerla más compacta. En este caso se utiliza la Transformada Wavelet Discreta (DWT, Discrete Wavelet Transform), donde los parámetros a y b son discretizados como $a = 2^j$ y $a = 2^j m$ con m y j siendo enteros. La DWT se realiza utilizando un algoritmo basado en un análisis multiresolución en el cual la señal original se descompone en otras señales aplicando un banco de filtros pasa-bajo y pasa-alto seguidos de una etapa de submuestreo a 2 como se muestra en la Figura 2.11. La señal original es dividida en dos componentes: Uno de baja frecuencia compuesto por un vector de coeficientes, llamado de aproximación A_1 y otro componente de alta frecuencia, conocido como detalle D_2 . Este proceso se repite hasta un número M de niveles. Cada nivel $j = 1, \dots, M$ está constituido por un par de componentes (A_j, D_j) , cada uno con la mitad de coeficientes que el vector de aproximación precedente A_{j-1} . Los bancos de filtros aplicado denotan un conjunto de bandas, comenzando con la de menor frecuencia, como: $b_1, b_2, \dots, b_M, b_{M+1}$ para un total de M niveles; con los correspondientes anchos de bandas $B_A, B_M, \dots, B_2, B_1$ y frecuencias centrales: $f_A, f_M, \dots, f_2, f_1$. El ancho de banda del filtro al nivel j es (Gu et al., 2000):

$$B_j = \frac{f_s}{2^{j+1}}, \quad B_A = B_M \quad j = 1, 2, \dots, M \quad (2.4)$$

Donde B_A es el ancho de banda del filtro de aproximación. La frecuencia central de los filtros en el nivel j :

$$f_j = \frac{3f_s}{2^{j+2}}, \quad f_A = f_M - B_M, \quad j = 1, 2, \dots, M \quad (2.5)$$

Donde f_s es la frecuencia de muestreo.

En la Figura 2.12 se muestra la respuesta en frecuencia de los filtros wavelet para 3 niveles. Los filtros tienen una relación de una octava de ancho de banda como es definido por la ecuación (2.4). Aquí, $B_1 = 1/4$, $B_2 = 1/8$ y $B_3 = B_A = 1/16$.

El conjunto total de detalles D_j y la aproximación A_M constituyen la señal. La energía de toda la señal esta también contenida en este conjunto de parámetros. Calculando la energía de cada detalle es posible conocer la energía contenida en esa banda de frecuencia B_j para una señal en concreto. Esto puede ser utilizado para conformar un patrón o huella distintivo de cada defecto.

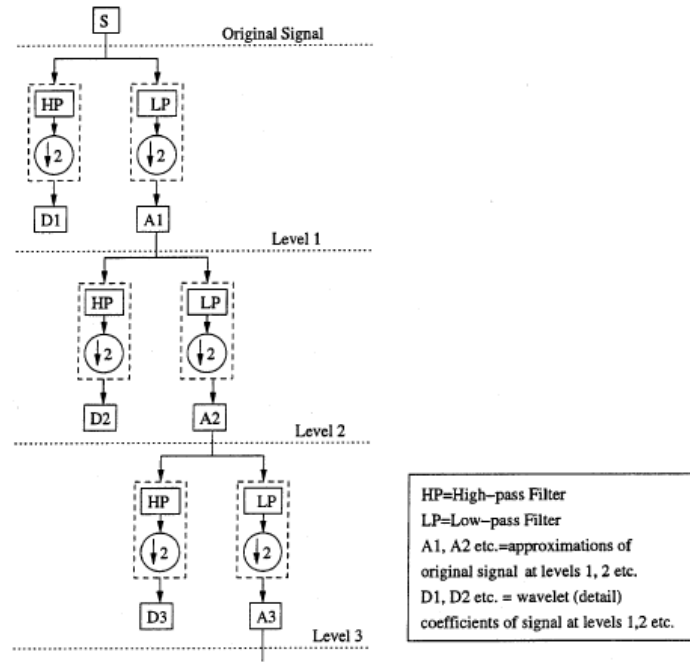


Figura 2.11. Análisis multiresolución para descomposición con la DWT (Sahoo et al., 2005)




Figura 2.12. Respuesta en frecuencia de filtros wavelet para $M=3$. El eje de frecuencia está normalizada a la unidad. (Gu et al., 2000)

La energía por nivel o banda PE_j^D es dada en porcentaje y se calcula con:

$$PE_{\rho}^D = \frac{E_{\rho}^D}{E_{Tot}} 100 \quad (2.6)$$

Donde $E_{\rho}^D = \sum_{k=1}^T D_j(k)^2$ es la energía del detalle en el nivel ρ , con un número T de coeficientes; $E_{Tot} = \sum_{j=1}^M E_j^D + \sum_{k=1}^T A_M(k)^2$.

La técnica de huellas de energía para identificación de DP fue primero propuesto en (Boczar et al., 2004). En este trabajo se utilizaban objetos de ensayo modelando varios tipos de defectos: partículas flotando en aceite, burbujas en aceite, un electrodo y varios electrodos afilados rodeado de aceite. Se utilizó el método de detección acústica para las medidas de las descargas. A las señales se les calculó la huella de energía creando patrones distintivos para cada defecto. Esta técnica también se utiliza en los trabajos de (Kundu et al., 2012) para identificación por medio de fractales y en (Boczar et al., 2014) donde se propone un sistema para identificación automática con redes neuronales de DP en transformadores de potencia. En el estudio de (Yang et al., 2003) es utilizada para obtener patrones de señales UHF desde fuentes de descarga parcial provenientes de partículas metálicas libres en el aceite de un transformador.

En (Boya et al., 2015a) es utilizada la técnica de huella de energía para identificación de dos tipos de DP: internas y superficiales. Se diseña un experimento con objetos de ensayos modelando un defecto tipo electrodo afilado con aislante sólido en la punta y rodeado de aceite. Este defecto generaba DP superficiales. También se modelo un defecto con dos electrodos con capas de papel aislante con pequeñas burbujas en medio. Este defecto generaba DP internas. Se utilizó el método de detección acústicas para registrar las señales. En la Figura 2.13 se muestran ejemplos típicos de las señales registradas en el experimento. La DP interna tiene menor amplitud que la DP superficial y menor duración. En la Tabla 2.1; **Error! No se encuentra el origen de la referencia.** se muestran las bandas de frecuencia consideradas y su correspondiente porcentaje de energía. Estos valores fueron calculados utilizando la ecuación (2.10). Para este análisis DWT fue utilizada la Wavelet madre Daubechies 20 con 4 niveles de descomposición y una $f_s = 1$ MHz. Desde la distribución de energía por banda fue posible establecer huellas de energía distintivas para los dos tipos de fuentes de DP.

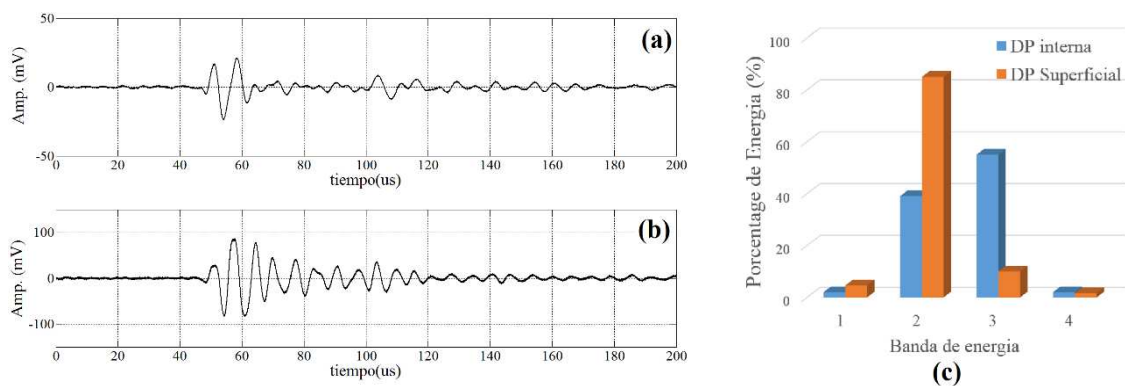


Figura 2.13. Extracción de características por medio de DWT. a) Señal acústica desde DP interna; b) Señal acústica desde DP superficial; c) Huellas DWT para DP interna y superficial.

Tabla 2.1. Porcentaje de energía por nivel de descomposición para DP internas y superficiales.

Nivel	Banda de Frecuencia (kHz)	DP Interna (% de energía)	DP Superficial (% de energía)
1	500-250	2.1	4.4
2	250-125	39.6	83.6
3	125-62.5	53.4	10.2
4	62.5-31.25	1.9	1.5

2.5. Localización de las descargas parciales

La posibilidad de localizar las fuentes de DP es una de las ventajas más importante de la detección acústica y electromagnética. Para la localización es necesario utilizar un arreglo de sensores ya sean acústicos o UHF en torno a la zona donde se sospecha de la actividad. La detección acústica es utilizada principalmente para localizar fuentes de DP en transformadores de potencia, corriente y tensión, interruptores, GIS, cables de potencia y capacitores. Con un arreglo de antenas UHF, además de la posibilidad de localización de descargas en transformadores y GIS, se extiende a localización en diferentes puntos en una subestación aislada por aire.

Para la localización es necesario calcular el tiempo de llegada de los pulsos a cada sensor y por triangulación obtener la coordenada del sitio de la descarga. Para realizar esta tarea existen dos métodos: localización por tiempo de llegada y localización por diferencias de tiempo. En el primer método para estimar las coordenadas espaciales de una fuente son necesarios al menos tres sensores. Se emplea los tiempos absolutos de cada pulso medidos desde su generación hasta su llegada al sensor. A este tiempo se le

conoce como tiempo de llegada (TOA, siglas en ingles de Time On Arrival). Una vez determinados los TOA se emplea triangulación geométrica por medio de un sistema de ecuaciones no lineales como sigue ([Lundgaard, 1992b](#)), ([Moore et al., 2005](#)):

$$(v\tau_i)^2 = (x - x_i)^2 + (y - y_i)^2 + (z - z_i)^2 \quad (2.7)$$

Donde v es la velocidad de propagación de la señal; τ_i es el TOA entre la fuente y el sensor i ; x, y, z son las coordenadas de la fuente; x_i, y_i, z_i las coordenadas del sensor i e $i = 1, 2, 3$.

Para la obtención de los TOA es necesario conocer el tiempo que toma la señal desde la fuente hasta el sensor. Una técnica para obtener esto es combinar el método de detección eléctrico o electromagnético con el acústico. Dada que la velocidad de las ondas eléctricas o electromagnéticas presentan valor de velocidad mucho mayor que la velocidad de las ondas mecánicas, se puede asumir que el tiempo en el cual se detecta la emisión eléctrica o electromagnética es el momento en el cual se genera la onda acústica. Ejemplos de esta técnica de localización se encuentra en los trabajos de ([Rubio-Serrano et al., 2012](#)) para el método eléctrico-acústico y en ([Coenen et al., 2012](#)) para el método UHF-acústico.

Cuando no se dispone de un medio para determinar el inicio temporal del pulso se realiza la localización utilizando las diferencias de tiempos de llegada (TDOA, siglas en ingles de Time Difference On Arrival) a cada sensor. En la Figura 2.14 se presenta un modelo geométrico para el cálculo de los TDOA usando cuatro sensores. Como puede observarse, la fuente de DP está más cerca al sensor X1 por lo que a la señal emitida le toma el menor TOA con respecto a los demás sensores. Como no se cuenta con ninguna referencia que dé información del inicio de la señal no es posible conocer éste TOA ni el de los demás sensores. Sin embargo, si se fija X1 como punto de referencia y se utiliza para obtener los TDOA entre este sensor los otros tres, X2, X3 y X4, es posible calcular las coordenadas de la fuente utilizando triangulación. Esto se realiza modificando la ecuación (2.7) para quedar con un sistema de cuatro ecuaciones cuadráticas no lineales ([Ramírez-Niño et al., 2009](#)):

$$\begin{aligned}
0 &= x^2 + y^2 + z^2 \\
(v\tau_{12})^2 &= (x - x_2)^2 + (y - y_2)^2 + (z - z_2)^2 \\
(v\tau_{13})^2 &= (x - x_3)^2 + (y - y_3)^2 + (z - z_3)^2 \\
(v\tau_{14})^2 &= (x - x_4)^2 + (y - y_4)^2 + (z - z_4)^2
\end{aligned} \tag{2.8}$$

Donde τ_{12} , τ_{13} y τ_{14} son los TDOA entre los pares de sensores X1-X2, X1-X3 y X1-X4, respectivamente. Para simplificar el problema X1 está en el origen (0,0,0) por lo que su TOA es $\tau_1 = 0$.

Para resolver este sistema de ecuaciones no lineales cuadráticas existen varios métodos. Uno de los más comunes es el método de Newton-Raphson, el cual aplica expansión de la serie de Taylor para linealizar el conjunto de ecuaciones (2.8) (Foy, 1976), (Tonieri, 1984). Este método es iterativo y se debe fijar un valor inicial de coordenadas, el cual normalmente es el origen (0, 0, 0). En los trabajos (Schau et al., 1987) y (Chan et al., 1994) se propone una forma pasiva para resolver el sistema de ecuaciones (2.8) sin utilizar técnicas de optimización. La determinación de las coordenadas de la fuente es realizada resolviendo el sistema de ecuaciones por medio de manipulaciones matriciales.




Figura 2.14. Modelo geométrico espacial para la obtención de los TDOA.

El paso más importante para la localización es la estimación de los TDOA. En la Figura 2.15 muestra un ejemplo de las señales registradas por los cuatro sensores X1, X2, X3 y X4. En este caso la señal del sensor X1 es tomada como referencia y los TDOA son calculados restando el punto inicial de esta señal con el punto inicial de las otras señales.

En este ejemplo el punto inicial de cada señal está muy claro y es fácil de determinar sin embargo cuando existe ruido o la presencia de otras fuentes de DP que se mezclan en el sensor se hace muy difícil reconocer el inicio de la señal. En la Figura 2.16 se muestran dos señales electromagnéticas desde un evento interno de DP medidas por dos antenas UHF, X1 y X2. Se ha marcado el inicio del evento en cada canal y el TDOA, que es calculado a partir de estos puntos. Se puede observar que antes de cada evento hay gran cantidad de ruido de fondo. En este ejemplo, es posible distinguir el inicio ya que las señales tienen una amplitud mucho mayor que el ruido, sin embargo, este no siempre es el caso. Por otro lado, en el caso de automatizar el proceso de localización es necesario fijar umbrales. Si este umbral está por debajo de algunos pulsos desde la señal de ruido, se obtendrán TDOA que darán información errónea para la localización.




Figura 2.15. Obtención de los TDOA utilizando las señales medidas.




Figura 2.16. Par de señales reales UHF con los puntos de llegada a los sensores señalizados.

En condiciones reales la obtención de los TDOA no es una tarea sencilla y es afectada por diversos factores: ruido, el tiempo de respuesta y la posición de los sensores, el patrón de radiación de la descarga, la reverberación que sufren las señales en su propagación desde la fuente hasta el sensor y la superposición con emisiones desde otras fuentes de DP. Por estas razones se han propuestos e implementados varios métodos para la obtención de los TDOA, cada uno con sus ventajas y condiciones operativas específicas.

2.5.1. Estimación de TDOA por el método de umbral

En el método de umbral propuesto en (Moore et al., 2005) se utilizan cuatro sensores los cuales miden simultáneamente la señal desde la DP. Se adquiere una cantidad N de muestras por cada sensor, el cual es llamado canal $x_q(k)$, donde $q = 1, 2, 3, 4$ y $1 \leq k \leq N$. Se busca el pico máximo del ruido en uno de los canales i :

$$s_i = \max |x_i(t)| \quad (2.9)$$

Para $t = 1, \dots, M$ donde M indica las primeras muestras antes de iniciar la onda directa de la señal. Este valor se asigna de manera empírica. Un valor de umbral T_i es establecido como un múltiplo de s_i , típicamente de 2. La posición del inicio de la señal τ_i es encontrada como el primer valor de t que satisface $|x_i(t)| > T_i$ cuando t es variado de M hasta N , máximo valor de muestras de la señal. Los TDOA son encontrado como la diferencia entre las posiciones de inicio τ_i para cada canal, ejemplo: $\tau_{12} = \tau_1 - \tau_2$.

2.5.2. Estimación de TDOA por el método del primer pico

En este método ([Sinaga et al., 2012b](#)), las señales de cada canal son convertidas en unipolares (se obtiene el valor absoluto de toda la señal) y luego son normalizadas, de la manera que tengan valores entre 0 y 1. Se escoge un umbral, típicamente 0.25, y se busca el primer pico que pasa este valor para cada canal utilizando un detector de pico (es necesario fijar un ancho de ventana en muestras). Este valor es utilizado para determinar el tiempo de llegada de la señal. En la Figura 2.17 se muestra un ejemplo de la obtención de los TDOA con este método.




Figura 2.17. Par de Señales UHF normalizadas y obtencion del primer pico de cada señal para la obtencion de los TDOA, ([Sinaga et al., 2012b](#)).

2.5.3. Estimación de TDOA por el método energía acumulada

La energía de las señales PD es dependiente de la distancia. Si se realiza una sumatoria de energía en el tiempo sobre cada canal se espera que este valor aumente con el tiempo. Este valor es utilizado para comparar los puntos de incremento de la energía debido a la señal que llega a los sensores y utilizado para obtener los TDOA. La energía acumulada en un tiempo t_k :

$$U(t_k) = \sum_{i=1}^k (V(t_i))^2 \quad (2.10)$$

A este método se le llama método de energía acumulada ([Judd et al., 2005](#)). En la Figura 2.18 se muestra un ejemplo típico. Las curvas en azul y rojo representan la energía

acumulada de dos canales. Los círculos indican el punto de un incremento repentino de energía y que indica el inicio de la señal PD. Este punto es conocido como “Knee point”. Para la asignación de este punto no hay definición matemática y debe ser realizado de manera empírica.




Figura 2.18. Grafica de energía acumulada para un par de señales UHF, (Judd et al., 2005).

2.5.4. Método de correlación cruzada

Este método mide la similitud entre dos formas de onda como una función de un corrimiento el tiempo aplicado a una de las señales. Una de las señales es considerada en una posición estacionaria y la otra es cambiada hacia otro punto y comparada. Si una de las señales es una versión retardada de la otra el máximo valor de correlación apuntará al TDOA τ_{CC} entre las dos señales (Sinaga et al., 2012b):

$$\tau_{CC} = \max \Psi_{CC}[m] \quad (2.11)$$

Donde $\Psi_{CC}[m] = E\{x_1(t)x_2(t+m)\}$. Existe una versión más robusta y popular de este metodo llamada **Phase Transform (PHAT)** o **Generalized Cross Correlation** (Chen et al., 2006) donde el TDOA τ_ϕ entre dos señales es obtenido utilizando:

$$\tau_\phi = \max \Psi_\phi[m] \quad (2.12)$$

Donde

$$\Psi_\phi[m] = S_{x_1x_2}(f)/|S_{x_1x_2}(f)| \text{ y}$$

$S_{x_1x_2}(f)$ es el Potencia espectral cruzada entre los dos canales.

Los primeros tres métodos necesitan la ayuda de un humano experto para colocar los umbrales o el “knee point”. En el caso de un bajo radio de señal a ruido u interferencias ajenas a la PD, estos métodos suelen dar errores en los TDOA. Los métodos de correlación cruzada y PHAT se basan en la asunción que las señales en los canales son versiones similares, pero retardas de la fuente. En un ambiente donde haya fuerte reverberación y ruido puede dar TDOA erróneos ya que su estructura solo está diseñada para enfrentar retardos sin tomar en cuenta las reflexiones. En ([Boya et al, 2015b](#)) se ha propuesto un nuevo método para estimación de los TDOA utilizando un algoritmo basado en Análisis de Componentes Independientes o (ICA, siglas en inglés de Independent Component Analysis) y detección con antenas UHF. En esta propuesta de localización no es necesario fijar umbrales y puede enfrentar el problema de reverberación. Son utilizado un arreglo de tres sensores para localización en dos dimensiones de una fuente de descarga tipo interna. Para obtener los TDOA, al algoritmo se le proporcionan las señales de dos sensores como las mostradas en la Figura 2.16. Par de señales reales UHF con los puntos de llegada a los sensores señalizados. El algoritmo estima dos filtros de longitud L . En la Figura 2.19 se muestra un ejemplo de la gráfica de estos filtros. La posición del parámetro con el máximo valor de amplitud es el TDOA de la fuente de DP.

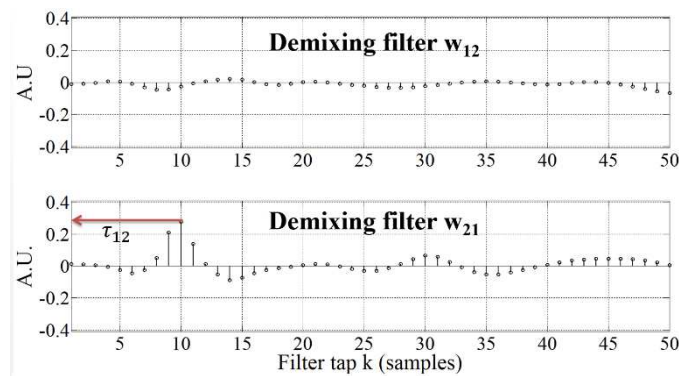


Figura 2.19. Parámetros del par de filtros estimados por el algoritmo BSS. Se muestra con una flecha roja el TDAO entre los dos sensores ([Boya et al, 2015b](#)).

Esta propuesta fue comparada con los demás métodos para estimación de TDOA mencionados anteriormente arrojando el menor valor medio de error en la localización de la fuente.

2.6. Identificación múltiples descargas parciales

En los métodos presentados hasta ahora siempre se asume la presencia de una sola fuente activa de DP, sin embargo, en condiciones reales existe la posibilidad que varias fuentes puedan estar activas de manera simultánea, de tal manera que los sensores obtienen una señal superpuesta de las emisiones de cada fuente. Esta situación puede llevar a información errónea sobre la condición real del aislante.

Además de las DP, los sensores registran señales desde diferentes fuentes de ruido las cuales tienden a superponerse en la señal de interés modificando sus características. Este ruido depende del sensor utilizado y de sus parámetros, tales como sensibilidad y respuesta en frecuencia. Por ejemplo, en el método convencional, se pueden acoplar a los conductores del circuito de medida señales impulsivas provocadas por controladores automáticos de velocidad de motores o por las emisiones electromagnéticas desde descargas tipo corona. En la detección acústica de DP en un transformador, el ruido puede proceder de fuentes acústicas diferentes a las DP y que emiten en el espectro ultrasónico, tales como el golpeo de las gotas de lluvia en el tanque del transformador, o provenientes de vibraciones causadas por la acción magnetoestrictiva del núcleo (ruido Barkhausen), o de bombas para la refrigeración, entre otras. En la detección electromagnética, el ruido proviene de señales impulsivas generadas por los controles de los motores y también de otras señales de comunicaciones que se encuentran en el espectro de medida como por ejemplo radio FM, televisión digital, GSM, UTMS, y WiFi).

De esta manera, en la detección es posible registrar señales desde varias fuentes de PD y fuentes de ruido lo que hace el proceso de identificación muy complejo y puede llevar a un juicio erróneo en el diagnóstico.

En esta tesis, los métodos propuestos para tratar con el problema de múltiples fuentes han sido dividido en métodos basados en los patrones PRPD y métodos basados en tiempo resuelto.

2.6.1. Múltiples fuentes de PD con métodos de identificación basados en PRPD

Cuando existen varias fuentes de DP en un equipo estas pueden generar patrones PRPD superpuestos lo que puede llevar a una identificación errónea del tipo de descarga ([Cacciari et al., 1993](#), [Lalitha et al., 2000](#)). En la Figura 2.20 se muestran patrones PRPD generados por dos tipos de descargas: superficiales en (a) y corona (b). En la gráfica (c) se muestran el patrón PRPD cuando son activados simultáneamente las dos fuentes de

DP. Debido que al sensor llegan las emisiones simultáneamente, los patrones PRPD de los dos tipos de DP se solapan y dificulta la distinción.

En un ambiente real siempre existe la probabilidad de un evento donde más de una fuente de DP este activa y puedan ser medidas en el sensor llevando a un juicio erróneo sobre un patrón PRPD y el defecto que lo ha causado. Para tratar con este problema se han propuesto dos métodos para la identificación: parámetros de la distribución Weibull y análisis wavelet de imágenes PRPD.

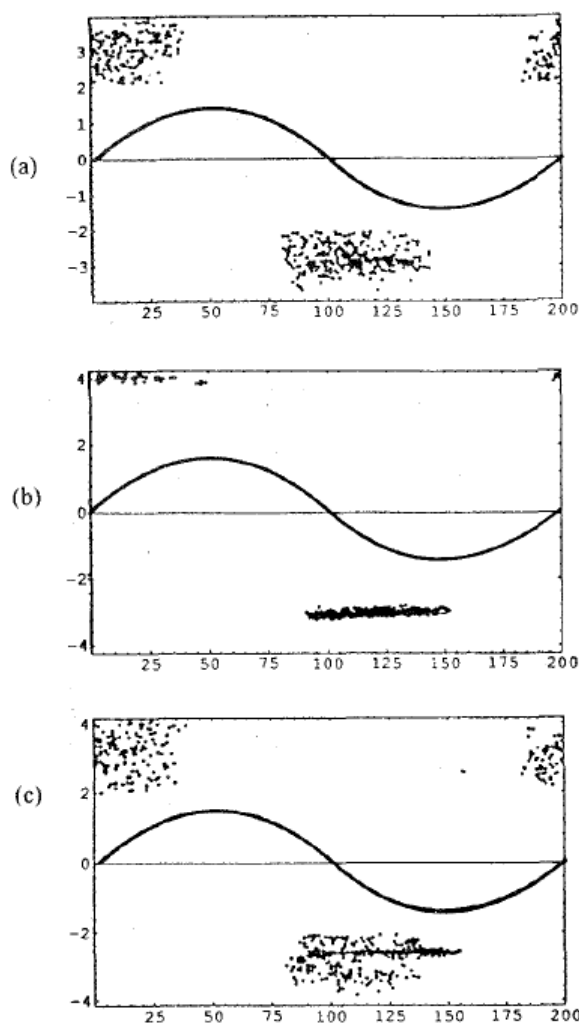


Figura 2.20. Ejemplo de los patrones PRPD. (a) DP superficial, (b) DP corona y (c) DP superficial y corona simultáneamente. El eje vertical representa la carga en pico coulombio y el eje horizontal, la fase ([Cacciari et al., 1993](#)).

Una de las soluciones propuestas consiste en utilizar la función acumulativa de distribución Weibull para modelar los patrones PRPD de cada tipo de descarga ([Cacciari et al., 1993](#)), ([Cacciari et al., 1995](#)), ([Cacciari et al., 1996](#)), ([Contin et al., 2000](#)). Esta distribución está definida como:

$$F(q) = 1 - \exp \left[- \left(\frac{q}{\alpha} \right)^\beta \right] \quad (2.13)$$

Donde q es el valor de carga máximo del pulso, α es la escala y β es el factor de forma de la distribución. Los valores α y β dependen de la forma del patron PRPD el cual a su vez depende del tipo de descarga. De esta manera, estos valores son utilizados como características distintivas de cada tipo de descarga. En la propuesta se crea una base de datos para cada fuente de DP individuales como corona, superficial e internas. Utilizando la ecuación (2.13) se obtiene el valor de los parámetros para cada tipo de descarga. Cuando se sospecha de la presencia de dos tipos de descargas en un equipo, se registran los patrones PRPD y se utilizan para obtener los nuevos parámetros los cuales son comparados con los parámetros de la base de datos de DP individuales. En el trabajo de ([Contin et al., 2000](#)) el método fue utilizado para identificar múltiples fuentes de DP con patrones PRPD que estaban casi solapados. El método se evaluó con datos desde combinaciones de pares de fuentes: superficial-corona, corona-corona e internas-internas ofreciendo resultados satisfactorios en la identificación.

Para abordar este problema de identificar varias fuentes en patrones PRPD con el método eléctrico, en ([Lalitha et al., 2000](#)) se propone un método de identificación basado en la descomposición Wavelet de imágenes de patrones PRPD. Cuando se realiza una descomposición Wavelet para imágenes esta produce por cada nivel tres imágenes: una destacando variaciones verticales, otra las horizontales u otra las diagonales. En el trabajo se demostró que las imágenes con las variaciones horizontales y verticales pueden ser utilizadas para discriminar entre dos tipos de DP. Por ejemplo: los patrones PRPD de las DP internas son resaltados más en las imágenes con variaciones verticales que las DP superficiales. Para el caso de las DP superficiales, son las variaciones horizontales. Si las imágenes de los patrones PRPD de cada tipo son mezclas cuando se aplica la descomposición a la imagen resultante esta produce: una imagen vertical similar a la imagen vertical de la DP interna y otra imagen horizontal similar a la imagen horizontal de la DP superficial. De esta manera, utilizando las imágenes verticales y horizontales de una imagen con patrones PRPD generados por dos DP es posible identificar los patrones originales PRPD de las DP individuales.

2.6.2. Múltiples fuentes de PD con métodos de identificación basados en tiempo resuelto

El efecto de superposición en los sensores debido a la presencia de múltiples fuentes de PD afecta las características de la forma de onda ([Contin et al., 2002](#), [Cavallini et al., 2003](#)). El método propuesto en ([Contin et al., 2002](#)) y ([Cavallini et al., 2003](#)) basado en los mapas T^2W^2 y lógica difusa se utiliza para abordar el problema de múltiples DP utilizando el método convencional eléctrico. Un ejemplo de la efectividad del método es mostrado en la Figura 2.21. Se registran pulsos de DP desde los terminales de un transformador de radio frecuencia usado en aviones, aplicando una tensión de 8 kV. En la gráfica (a) de la Figura 2.21 se muestra el patrón PRPD calculado desde la medición. En la gráfica (b) de la Figura 2.21 se presenta su correspondiente mapa tiempo-frecuencia donde es posible apreciar dos clústeres. En la gráfica (c) se muestran el patrón PRPD de los puntos agrupados del clúster más a la izquierda de la gráfica (b) y en la gráfica (e) un ejemplo del pulso. En un análisis del equipo se comprobó que estas señales provenían de una fuente de DP internas en el aislamiento. En la gráfica (d), se muestra el patrón PRPD de los puntos del clúster más a la derecha y etiquetado como fuente #2 debido a DP internas en localizadas en otro punto del aislamiento del transformador, específicamente micro-cavidades.

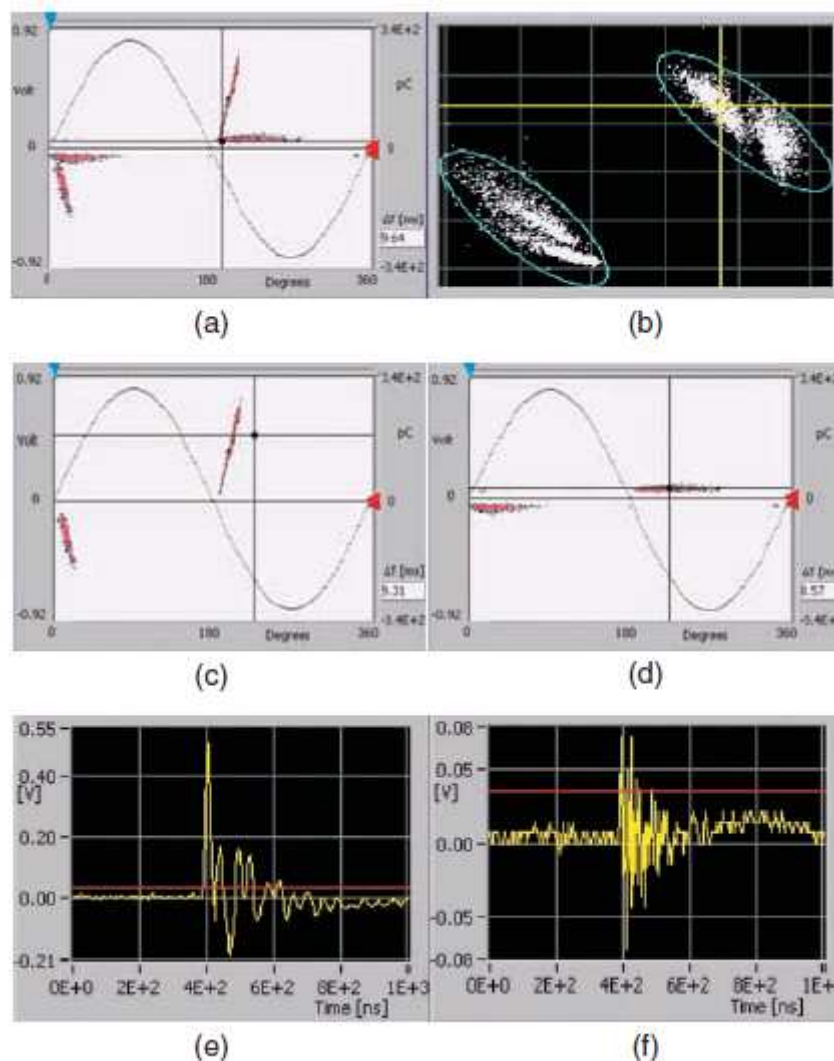


Figura 2.21. Ejemplo de separación de dos tipos de DP utilizando el método de mapa tiempo-frecuencia. a) patrón PRPD sin procesar, b) Mapa tiempo-frecuencia utilizado para la separación, patrones PRPD para la c) fuente #1 y d) fuente #2; pulsos representativos para e) fuente #1 y f) fuente #2 (Cavallini et al., 2003).

Otra propuesta, enfocada en el método convencional eléctrico fue presentada en (Hao et al., 2010 y Hao et al., 2011) y es basada en la asunción que diferentes tipos de fuentes de DP generan huellas únicas que son manifestadas por la distribución de energía con respecto a frecuencia y tiempo. En la propuesta se utiliza el método convencional eléctrico para la medida de los pulsos y con una frecuencia de muestreo de 500Mhz suficiente para obtener una forma de onda bien definida. A las señales se les aplica una descomposición Wavelet de cinco niveles utilizando una Wavelet madre Symlet 9. Después es calculado el porcentaje de energía de cada nivel. Para realizar esto se obtiene la energía total de cada pulso y después se obtiene el porcentaje correspondiente de cada nivel con respecto a la energía total. Cada nivel corresponde a una banda de frecuencia del espectro del pulso con un máximo definido por la mitad de la frecuencia de muestreo.

De este cálculo se obtiene una huella de energía constituida por cinco valores de energía correspondiente a las cinco bandas de frecuencias. Estas cinco bandas corresponden a 250 Mhz-125 MHz, 125 Mhz-62.5 MHz, 62.5Mhz-31.25 MHz, 32.25 Mhz-15.625 MHz y 15.625 MHz -7.8125 MHz. Después es realizado un Análisis de Componentes Principales o PCA (siglas en ingles de Principal Component Analysis). Esta técnica permite extraer componentes representativos de un conjunto de señales utilizando la varianza como característica. Los componentes con más varianza son extraídos hasta una cantidad establecida. Esto permite descartar componentes con la menor varianza, que representan el menor aporte de información en el conjunto de todas las señales. De este análisis son retenidos tres parámetros que representan los valores de energía más representativos de cada tipo de DP y que permiten representar las señales en un espacio tridimensional.

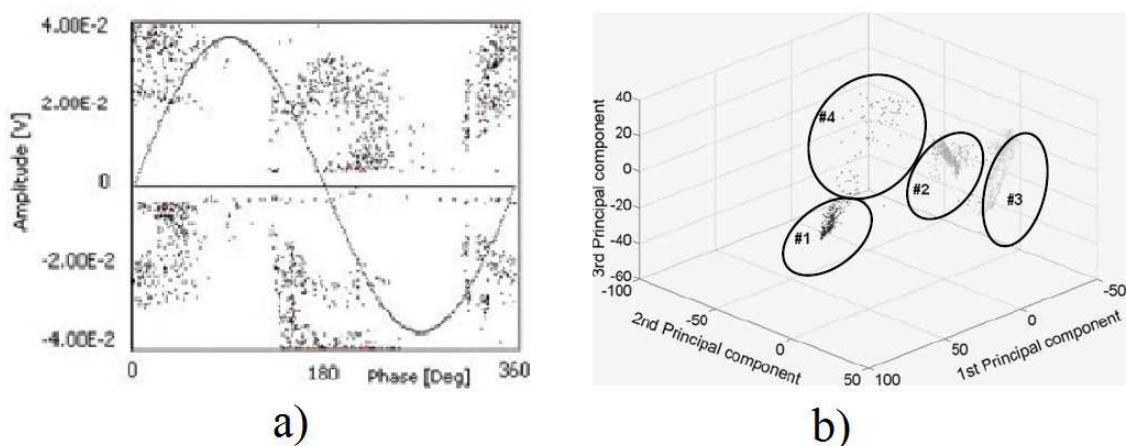


Figura 2.22. A) Patrón PRPD de DP en una barra Roebel de un generador síncrono con ruido eléctrico presente. b) Gráfica en tres dimensiones con los tres componentes principales de energía una vez realizado la descomposición Wavelet y Análisis de componentes principales, ([Hao et al., 2010](#) y [Hao et al., 2011](#)).

En la Figura 2.22 se muestra un ejemplo de este método. En la gráfica a) de esta figura se muestran el patrón PRPD obtenido de la medición de pulsos de DP generados por defectos en la cinta de aislamiento de una barra Roebel insertada en la ranura del estator de un generador síncrono con ruido eléctrico presente. A las señales medida se le calcularon sus huellas de energía por nivel y después fueron obtenidos los tres componentes utilizando PCA. En la gráfica b) de la Figura 2.22 son representados estos componentes en un espacio de tres dimensiones. Con el algoritmo Density-Based Spatial Clustering of Applications with Noise (DBSCAN) el cual es utilizado para identificar clúster en este tipo de espacios se calcularon de manera automática cuatro clústeres: #1, #2, #3 y #4. El clúster #1 es asociado al patrón PRPD y señal mostrada en la graficas a)

y b) de la Figura 2.23. Esta señal proviene de los defectos internos en la barra Roebel. Los clústeres #2 y #3 asociados a los patrones PRPD y señales c) y d) y e) y f) respectivamente, provienen del ruido eléctrico. De esta manera con este método es posible separar e identificar una fuente de PD desde una fuente de ruido. Además, en la propuesta se demostró la eficiencia del método para identifica dos fuentes internas generadas por defectos en dos puntos del aislador de un generador o una fuente interna de una superficial en un cable de potencia.

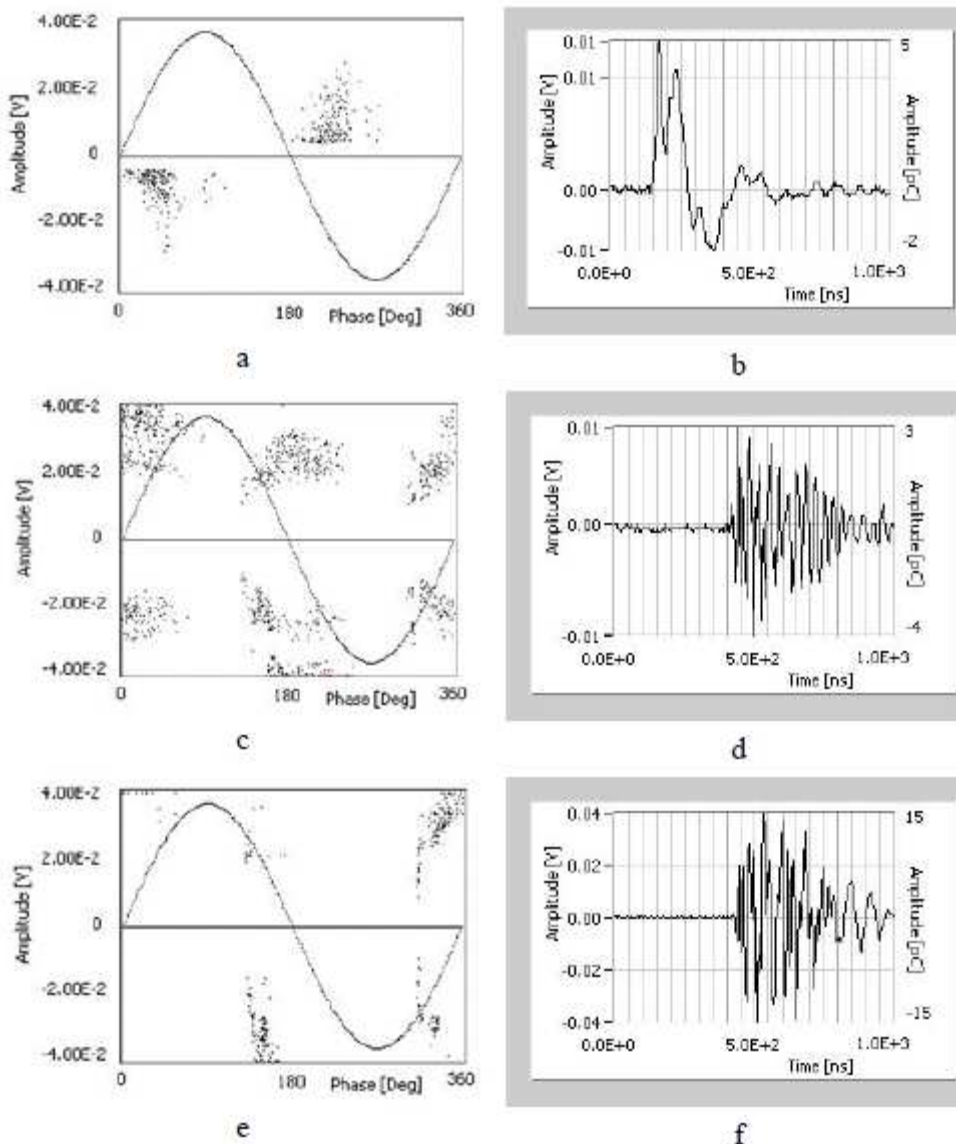


Figura 2.23. Patrones PRPD y sus señales representativas para tres clústeres en la Figura 2.22. a), c) y e) patrones PRPD del clúster #1, #2 y #3, respectivamente; b), d) y f) las señales relevantes representativas, ([Hao et al., 2010](#) y [Hao et al., 2011](#)).

En ([Kundu, et al., 2012](#)) se propone un método basado en descomposición Wavelet y fractales para identificar una y dos fuentes de DP activas. En este caso la propuesta utiliza

el método de medida acústico. Para demostrar la efectividad del método se realiza un experimento donde se emplean tres modelos de defectos para generar señales acústicas de DP como se muestra en la Figura 2.24: (a) DP tipo corona utilizando un modelo punta metálica-cilindro metálico plano con aire como aislante (punta-plano), (b) DP tipo superficial con un modelo cilindro metálico plano-cilindro metálico plano con papel en medio (plano-plano) y (c) DP tipo superficial utilizando un modelo cilindro metálico curvo-cilindro metálico plano con papel en medio (plano curvo-plano). Las señales son registradas utilizando el método acústico y posteriormente con la transformada Wavelet Symlet 7 descompuestas en cinco niveles. A cada nivel le es calculado el porcentaje de energía por banda de frecuencia lo que genera una huella representativa para cada tipo de DP. En la Figura 2.25 son mostradas estas huellas de energía. Las gráficas a) y b) de esta figura representan la distribución de energía para DP tipo corona: a) una sola fuente activa y b) dos fuentes activas. Las gráficas c) y d) la distribución para DP tipo superficial, para una fuente y para dos activas simultáneamente, respectivamente; y e) y f) para DP tipo superficial plano curvo-plano, para una fuente y dos activas, respectivamente. Las DP generadas por un modelo punta plano tiene la máxima energía para el nivel 2, las DP para plano-plano en el nivel 3 y las plano curvo-plano en el nivel 4. En este método todas estas gráficas son tratadas como imágenes y se le calculan las siguientes características: la dimensión fractal, que es una medida de la complejidad de la imagen y la lacunaridad, que mide la densidad de los píxeles de la imagen. En la Figura 2.26 gráfica (a) se muestra un ejemplo donde se muestra la dimensión fractal versus la lacunaridad para imágenes provenientes de señales de una sola fuente de DP (pntpln1) y dos fuentes de DP (pntpln1) tipo corona. En este caso, se forman dos clústeres: uno para el caso de una sola fuente activa (pntpln1) y el otro para dos fuentes activas simultáneamente (pntpln2). Una situación similar ocurre cuando se grafican estas dos características para cuando existe una sola fuente y dos fuentes en los casos plano-plano y plano curvo-plano. Sin embargo, si todos se grafican juntos quedan solapados. Para superar este problema, se utiliza el valor máximo de la distribución de energía por banda. Primero se verifica en qué nivel está el máximo valor de energía y después se evalúa si la señal es generada por una fuente o dos fuentes activas simultáneamente. Ejemplo: Si la distribución de energía de una señal a identificar tiene el máximo en el nivel 2, se identifica como una señal proveniente de un modelo punta-plano. Después se le calculan las dos características: dimensión fractal y lacunaridad, y si los valores están por encima de los valores 1 para la dimensión fractal

y 0.12 para la lacunaridad se le identifica como una señal proveniente de dos fuentes activas simultáneamente de tipo corona.




Figura 2.24. Modelos de defectos para generar señales acústicas de DP. a) Electrodo punta-plano para DP tipo corona, b) Electrodo plano-plano con aislamiento para generar DP tipo superficiales, c) electrodos cilindro plano para generar DP tipo superficiales, ([Kundu, et al., 2012](#)).




Figura 2.25. Distribución de energía de las señales acústicas de DP. a) Electrodo punta-plano, b) Dos electrodos punta-plano activos simultáneamente, c) electrodos plano-plano con aislamiento, d) Dos electrodos plano-plano activos simultáneamente, e) Electrodo cilindro-plano con aislamiento, f) dos electrodos cilindro-plano activos simultáneamente, ([Kundu, et al., 2012](#)).




Figura 2.26. Dimensión fractal vs lacunaridad para una sola fuente de DP corona activa con un modelo punta-plano (pntpln1) y dos fuentes de DP corona activas simultáneamente con un modelo punta plano (pntpln2), ([Kundu, et al., 2012](#)).

En ([Tang et al, 2010](#)) se utiliza Separación Ciega de fuentes o (BSS, Blind Source Separation) para la identificación de DP en un ambiente de múltiples fuentes activas y el método UHF para la medición de las emisiones de las descargas. Ya que las señales emitidas por multiples fuentes individuales se mezclan con BSS es posible revertir este proceso utilizando un algoritmo de separación basado en la independencia estadística de las fuentes originales. El resultado es una estimación de estas señales fuentes las cuales contiene las informaciones para la identificación de las DP, pero sin distorsión. En el trabajo de Tang se utilizan señales de DP obtenidas en una GIS de dos tipos de defectos: partículas metálicas flotantes y cavidades en uno de los espaciadores de la GIS generando descargas de tipo internas. Estas señales son registradas y sintéticamente mezcladas. Posteriormente, se aplica el algoritmo Maximizing Signal Noise Ration (MSNR) el cual está basado en BSS para revertir el proceso de mezclado.

2.7. Discusión sobre los métodos de identificación para múltiples DP

En la sección anterior se presentaron varias propuestas para tratar el problema de múltiples fuentes activas enfocadas en los patrones PRPD y tiempo resuelto. La utilización de parámetros Weibull demuestra una notable capacidad para distinguir cuando existen dos tipos de fuentes de DP sin embargo su éxito está limitado al nivel de solapamiento entre los patrones PRPD de las fuentes. Cuando la superposición es total el método no logra identificar apropiadamente. El análisis Wavelet de imágenes PRPD si alcanza la separación de las fuentes a pesar de un total solapamiento, pero la propuesta

sólo ha sido demostrada para mezclado sintético de imágenes de patrones PRPD provenientes de descargas individuales. No se extiende a mezclas generadas por varias fuentes reales activas. Con los mapas T^2W^2 con lógica difusa se logra la separación incluso con patrones PRPD solapados. Este método ha sido utilizado para señales generadas en equipo reales fuera del laboratorio. Sin embargo, es muy dependiente de la forma de onda de los pulsos. En el caso de dos o más fuentes activas, sus emisiones pueden llegar a superponerse en los sensores de tal forma que dos o más pulsos desde diferentes fuentes serán procesados como si fueran generadas por una sola fuente. Las características de tiempo y frecuencia de este nuevo pulso no contendrán información real del proceso ya que será una mezcla de pulsos de varias fuentes llevando a una identificación incorrecta. Esta misma dificultad puede ser encontrada cuando se utiliza el método de Descomposición Wavelet y Análisis de Componentes principales y el método de fractales ya que también utilizan características de la forma de onda.

En todos estos métodos no existe una propuesta para localización espacial de fuentes. Los métodos presentados sólo utilizan un sensor por lo que esta tarea no es posible de realizar en paralelo con la identificación. En esta tesis se propone la identificación y localización en un ambiente de múltiples DP. El problema de mezclado será enfrentado con un enfoque nuevo en el área de procesamiento de señales de descargas parciales llamado Separación Ciega de Fuentes o BSS.

CAPITULO 3

3. Análisis de componentes independientes

3.1. Introducción

Separación ciega de fuentes (BSS, Blind Source Separation) trata con el problema de recuperar una o varias señales mezcladas de las cuales tenemos muy poca información. Inicialmente el problema BSS fue abordado para tratar de entender la habilidad natural del cerebro humano de enfocarse en un específico sonido, mientras suprime otros, lo cual es llamado *cocktail-party problem* ([Cherry, 1953](#)). El problema de BSS se puede explicar por medio del siguiente ejemplo: Tenemos tres personas conversando simultáneamente y tenemos la necesidad de grabarlas con tres micrófonos para posteriormente escuchar sus conversaciones. En la Figura 3.1 se muestra esta situación A las tres personas les llamaremos fuentes \mathbf{s}_1 , \mathbf{s}_2 y \mathbf{s}_3 y a los micrófonos \mathbf{x}_1 , \mathbf{x}_2 y \mathbf{x}_3 . Al reproducir las grabaciones de cada micrófono, lo que se escucha es una mezcla de las voces y no una voz individual. Incluso, aunque cada micrófono sea colocado muy cerca de cada persona, siempre existe interferencia de las otras fuentes. El problema de BSS es buscar una manera de recuperar cada fuente individualmente pero sólo utilizando la información contenida en los micrófonos. Este problema también puede verse como una separación de las fuentes desde las mezclas y de allí el origen de su nombre.

BSS no sólo se trata con señales acústicas, sino que sirve como marco general de estudio donde se proponen algoritmos para la recuperación de señales fuentes generadas desde diversos procesos físicos, tales como: señales eléctricas en el cerebro o el corazón o señales electromagnéticas emitidas por un móvil o un radar. El principal enfoque para solucionar BSS es asumir la independencia estadística de las fuentes y es conocido como Análisis de Componentes Independientes (ICA, Independent Component Analysis). En ICA se utilizan algoritmos que integran en sus pasos una medida de la independencia entre las fuentes de tal forma que a medida que opera sobre las mezclas el resultado son señales lo más independientes entre sí. Como ha sido demostrado por ([Comon, 1994](#)), las señales resultantes son las fuentes originales que forman la mezcla.

Los campos en los cuales se ha aplicado ICA con más frecuencia son la biomedicina y acústica. En biomedicina se utiliza para mejorar al análisis de la actividad eléctrica del cerebro. Este análisis se fundamenta en el registro de señales eléctricas que son emitidas desde diversas partes del cerebro y que son medidas por sensores colocados en el cuero cabelludo. El conjunto de estas señales es llamado encefalograma o EEG (Electro-EncephaloGraphy). Un problema que enfrenta este análisis es debido a que distintas zonas del cerebro se pueden activar simultáneamente y generar emisiones eléctricas que se mezclan en los sensores. Además, otras señales ajenas a las EEG también llegan a superponerse. Estas señales son llamadas artefactos y son causadas por el movimiento de los ojos y la quijada. Es importante mencionar que debido a la rapidez de estas señales eléctricas el mezclado en los sensores se considera instantáneo, es decir, las emisiones no sufren retardos al llegar a cada sensor.

Para resolver el problema de mezclado se han propuesto soluciones basadas en ICA tales como: [Makeig et al., 1996](#), [Vigario, 1997](#), [Tang et al., 2002](#) donde el resultado es la separación y recuperación de las señales EEG. ICA también es utilizado para remover artefactos que se mezclan con señales eléctricas de la actividad del corazón o electrocardiogramas (ECG, ElectroCardioGram). Las ECG son registradas en distintos puntos cercanos al corazón para luego reconstruir la dinámica espacial de su actividad. Sin embargo, el movimiento consciente o inconsciente del paciente, su respiración y otras interferencias se mezclan con los sensores distorsionando las señales de interés y dificultando el análisis. ICA se propone para la recuperación de las señales ECG desde las mezclas ([Barros et al., 1998](#), [Vetter et al., 2000](#)) y para la extracción de la señal ECG fetal ([Cardoso et al., 1998](#), [Lathuawer et al., 2000](#)). Otra aplicación de ICA en Biomédica es como parte de una Interfase cerebro-maquina o (BCI, Brain Computer Interface). En BCI las señales EEG son registradas por varios sensores en el cuero cabelludo. Utilizando la actividad de diferentes zonas del cerebro las cuales son activadas por la intención de un usuario, es posible codificarlas y aplicarlas para controlar sillas de ruedas, prótesis o una computadora. Como en el caso del análisis de señales EEG, en los sensores las señales eléctricas se mezclan, por lo que ICA es utilizada para separarlas y remover artefactos ([Rebsamen et al., 2010](#), [Del Castillo et al., 2011](#), [Shih et al., 2012](#)).

Otro campo de aplicación de ICA es la acústica. En el ejemplo de la Figura 3.1 donde se ejemplifica el problema de BSS el mezclado de las voces puede ser tratado con ICA. En este caso un algoritmo basado en ICA debe enfrentar un mezclado convolutivo debido a que las ondas acústicas recorren múltiples caminos sufriendo rebotes y retardos antes

de llegar a los micrófonos. Podemos destacar los trabajos de ([Nguyen Thi et al., 1995](#), [Charkani et al, 1999](#), [Douglas et al., 2005](#)) para la separación de señales voz y música. En ([Ehlers et al., 1997](#), [Choi et al., 2002](#)) ICA es utilizado como parte de un sistema de reconocimiento de voz. En ([Lombard et al, 2011](#)) se utiliza para la localización espacial de múltiples fuentes acústicas. En este caso parámetros estimados por ICA y utilizado por el algoritmo para la separación, también ofrecen información sobre los TDOA de las fuentes y que son utilizados para localizarlas. En este trabajo se explora la posibilidad de dar seguimiento a fuentes en movimiento útiles para aplicaciones como videoconferencias y sonares.

Además de biomédica y acústica, ICA ha sido aplicada en una gran diversidad de campos, tales como: procesamiento de imágenes ([Loghmari et al., 2006](#)), telecomunicaciones ([Gao et al., 2011](#)), finanzas ([Back et al., 1997](#)) y calidad en los sistemas de potencia ([Ruiz-Llata, et al., 2011](#), [Lima et al., 2012](#)). Es importante mencionar que hasta la fecha en los trabajos sobre mezclas reales los resultados de ICA no logran un 100% de separación de las fuentes, sin embargo, reducen en gran medida la interferencia de las otras fuentes y posibilitan la identificación de la fuente de interés.

En esta tesis, ICA se presenta como una propuesta para enfrentar el problema de mezclado por múltiples fuentes de DP. Como se discutió en la sección 2.6, la existencia de varias fuentes de DP cambian las características de las señales detectadas en el sensor por causa del mezclado. Como se presentó en esta introducción, ICA ha sido aplicado al problema de mezclado por lo que se utilizan los resultados de estos trabajos como referencia para aplicarlos en la separación de mezclas de señales desde múltiples fuentes de DP. En las siguientes secciones se presenta un marco teórico donde se introducen las bases matemáticas y estadísticas de ICA, los principales algoritmos y el algoritmo escogido para trabajar con las mezclas utilizadas en esta tesis.




Figura 3.1. Tres personas conversando y siendo grabadas por tres micrófonos. Donde s_i son las fuentes y x_i las mezclas.

3.2. Formulación del problema

BSS trata con el problema de recuperar fuentes que ha sido previamente mezcladas sin tener un conocimiento completo de estas fuentes. El problema puede ser formulado matemáticamente de la siguiente forma:

$$\mathbf{x}(n) = \mathbf{A}\mathbf{s}(n) \quad (3.1)$$

Donde $\mathbf{s}(n) = [s_1(n), s_2(n), \dots, s_N(n)]^T$ y $\mathbf{x}(n) = [x_1(n), x_2(n), \dots, x_M(n)]^T$ representan las fuentes y las mezclas, respectivamente; y n representa el índice del tiempo. Es importante introducir una nota sobre el índice del tiempo: “*Los algoritmos desarrollados para resolver el problema de BSS asumen que las fuentes y observaciones son señales continuas, sin embargo, en la práctica estas son discretizadas cuando son detectadas y almacenadas para un procesamiento posterior. De aquí en adelante, se asume que el tiempo de muestreo es suficientemente pequeño como para asumir que el tiempo de cada señal continuo. En toda la literatura revisada se asume de esta manera con resultados satisfactorios.*”

Por otro lado, para evitar confusiones sobre el concepto de mezcla, en esta tesis cada $x_i(n)$ será conocida como una “*observación*” del proceso de mezclado mediante el sensor $i = (1, 2, \dots, M)$. También, para el indicar el índice de cada fuente de DP se utilizará siempre la letra j , de esta forma $s_j(n)$, $j = (1, 2, \dots, N)$.

La matriz \mathbf{A} es un sistema de ecuaciones o transformación lineal sobre las fuentes, que indica la manera como son mezcladas las fuentes y que puede ser escrito como:

$$\mathbf{A} = \begin{pmatrix} a_{11} & \cdots & a_{1N} \\ \vdots & \ddots & \vdots \\ a_{M1} & \cdots & a_{MN} \end{pmatrix}$$

Los coeficientes a_{ij} se denominan parámetros de mezclado y representan la contribución de cada fuente a cada mezcla. Esta contribución normalmente se asume lineal. Este modelo es la representación de un mezclado instantáneo donde las señales llegan al mismo tiempo a todos los sensores.

En BSS se busca una manera de recuperar las fuentes $\mathbf{s}(n)$ desde las observaciones $\mathbf{x}(n)$ con la restricción de no contar con los parámetros de mezclados a_{ij} . Si aplicamos un método tal que nos permita encontrar un matriz $\mathbf{W} = \mathbf{A}^{-1}$ podemos resolver $\mathbf{s}(n) = \mathbf{W}\mathbf{x}(n)$ y recuperar las fuentes, donde

$$\mathbf{W} = \begin{pmatrix} w_{11} & \cdots & w_{1M} \\ \vdots & \ddots & \vdots \\ w_{N1} & \cdots & w_{NM} \end{pmatrix}$$

Para encontrar \mathbf{W} es necesario realizar alguna asunción sobre \mathbf{A} y $\mathbf{s}(n)$. El enfoque más utilizado es asumir que las fuentes $\mathbf{s}(n)$ son estadísticamente independientes. Este enfoque, que es conocido como de Análisis de componentes independientes o ICA (Independent Component Analysis), fue propuesto por ([Comon, 1994](#)). Utiliza el siguiente modelo lineal:

$$\mathbf{y}(n) = \mathbf{W}\mathbf{x}(n) \tag{3.2}$$

Donde $\mathbf{y}(n) = [y_1(n), \dots, y_N(n)]^T$ son conocida como las estimaciones de las fuentes y $y_j(n)$, $j = (1, 2, \dots, N)$. Basándose en la independencia estadística de las fuentes y asumiendo que hay igual cantidad de fuentes y observaciones ($M = N$) por lo que la matriz \mathbf{A} es invertible, en ICA se proponen algoritmos que tengan objetivo adaptar la matriz \mathbf{W} de tal manera que haga a cada $y_j(n)$ los más mutuamente independientes como

sea posible. Las estimaciones $y_j(n)$ se les conoce como componente independiente o IC (Independent Component).

En la Figura 3.2 se muestra un diagrama de bloques de la operación de ICA. Las fuentes $\mathbf{s}(n)$ y la matriz de mezclado \mathbf{A} representan un ambiente desconocido del que sólo tenemos acceso a través de las observaciones $\mathbf{x}(n)$. Se puede resolver el problema si se encuentra una matriz de pesos \mathbf{W} , tal que los componentes de $\mathbf{y}(n)$ sean lo más independientes entre sí como sea posible. En el caso óptimo esto lleva a:

$$\mathbf{W} = \mathbf{\Lambda P A}^{-1} \quad (3.3)$$

Donde $\mathbf{\Lambda}$ es una matriz diagonal no singular, \mathbf{P} es matriz permutación (orden de las fuentes estimadas) y \mathbf{A}^{-1} es la inversa de la matriz de mezclado.




Figura 3.2. Diagrama de bloques de la operación para resolver el problema BSS.

La ecuación (3.3) muestra el problema de indeterminación de ICA debido al cual no es posible conocer el orden en el cual las fuentes fueron mezcladas y tampoco su varianza original. Sin embargo, se preserva la forma de onda de las fuentes que para los fines de esta propuesta es suficiente.

El fundamento de ICA es la independencia estadística, la cual puede ser definida en términos de densidades de probabilidad. Si tenemos dos fuentes \mathbf{s}_1 y \mathbf{s}_2 , se dicen que son estadísticamente independientes si y sólo si su densidad de probabilidad conjunta $p(\mathbf{s}_1, \mathbf{s}_2)$ puede ser factorizada en sus densidades de probabilidad marginales $p(\mathbf{s}_1)$ y $p(\mathbf{s}_2)$:

$$p(\mathbf{s}_1, \mathbf{s}_2) = p(\mathbf{s}_1) p(\mathbf{s}_2) \quad (3.4)$$

Donde $p(\cdot)$ representa la densidad de probabilidad. La ecuación (3.4) también puede ser expresado de la siguiente manera:

$$p(\mathbf{s}_1, \mathbf{s}_2) = \prod_{i=1}^2 p(\mathbf{s}_i)$$

Donde $\Pi()$ es el producto de las densidades de probabilidad.

3.3. Algoritmos para ICA

La operación de ICA está basada en tres aspectos fundamentales:

1. Determinación de un modelo paramétrico el cual provee una representación de la estructura de separación y restringe la solución a un espacio en particular,
2. Un criterio basado en la búsqueda de la independencia estadística, con el cual se puede medir la calidad de la solución,
3. Un algoritmo de optimización, que por medio de la minimización o maximización del criterio encuentra la solución en el espacio del modelo paramétrico.

3.3.1. Modelo paramétrico de separación

El modelo de separación que se utiliza como referencia en un algoritmo ICA establece el número de parámetros cuyos valores hay que estimar para obtener las fuentes. Por ejemplo, la ecuación (3.2) establece un modelo paramétrico de separación representado por los coeficientes de la matriz \mathbf{W} , de tamaño $N \times M$ ($M \geq N$). Este modelo es lineal y se aplica para separación de fuentes que se han mezclado de manera instantánea. Este tipo de modelo es aplicado cuando se trabaja con procesos físicos donde las señales viajan a tal velocidad y distancia que el tiempo que toma la señal en viajar desde la fuente a los sensores es considerada instantánea y no hay retardos. Un ejemplo es cuando se trabaja con señales EEG generadas en el cerebro, las cuales son señales eléctricas que viajan a muy altas velocidades en distancias muy cortas ([Makeig et al., 1996](#)). En este caso se aplica el modelo de separación de la ecuación (3.2).

Cuando un proceso físico es detectado por sensores que están a cierta distancia de tal manera que las señales desde las fuentes llegan a diferentes tiempos a cada sensor el mezclado no se considera instantáneo y se debe aplicar un modelo lineal convolutivo.

Este modelo toma en cuenta el retardo y atenuación de las señales debido a su propagación en un medio, en el cual multiples reflexiones debido a paredes, pisos u otros objetos. En la Figura 3.3 puede observarse un ejemplo de este problema para el caso de dos fuentes de descargas parciales que son detectadas por dos sensores UHF. Los frentes de onda de cada emisión son modelados por rayos. Como puede observarse, hay rayos que cubren una mayor distancia debido a su reflexión por las paredes. Estos rayos llegan con un retardo mayor que los rayos directos además de sufrir una mayor atenuación debido a que recorren más distancias que los rayos directos. El resultado es un mezclado en el sensor x_1 de una señal que viajan de manera directa desde la fuente s_1 , una señal directa desde s_2 con retardo y multiples copias retardadas de las fuentes s_1 y s_2 debido a las reflexiones. En el sensor x_2 ocurre algo similar.

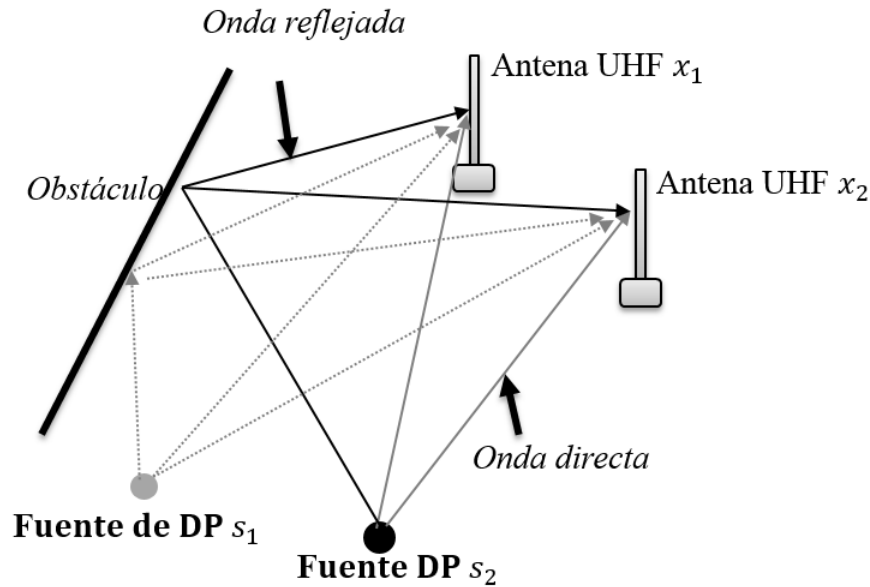


Figura 3.3. Dos fuentes DP emitiendo ondas electromagnéticas. Se muestran las trayectorias de los frentes de onda. Los sensores captan copias distorsionadas de las emisiones debido al medio.

En un sistema lineal convolutivo se asume que las fuentes sufren una convolución con una serie de filtros de respuesta impulso infinita o FIR (Filter Impulse Response) los cuales representan las características de propagación (retardos y reflexiones) de las fuentes en el medio. Este proceso es modelado por la ecuación ([Comon et al., 2010](#)):

$$x_i(n) = \sum_{j=1}^N \sum_{k=0}^{L-1} a_{ijk} s_j(n-k) \quad (3.5)$$

Donde $s_j(n)$ son las ($j = 1, 2, \dots, N$) fuentes, $x_i(n)$ son las señales medidas por los ($i = 1, 2, \dots, M$) sensores u observaciones, k es el retardo en muestras y n es el índice de tiempo. En este modelo, L es la longitud en k muestras de los filtros y representa la máxima longitud de propagación tomando en cuenta las reflexiones. Los coeficientes a_{ijk} son los correspondientes coeficientes de mezclado que indican la contribución de la fuente j en un instante $(n - k)$ a la mezcla i en el instante n .

Para abarcar todo el proceso convolutivo los filtros de la ecuación (3.5) idealmente deben tener longitud infinita, pero en situaciones prácticas la longitud L puede tener valor finito. Las señales emitidas desde las fuentes tienden atenuarse por la distancia y absorción del medio, de tal forma que su contribución es insignificante cuando ha sufrido muchas reflexiones.

La ecuación (3.5) puede ser escrita en forma matricial como:

$$\mathbf{x}(n) = \sum_{k=0}^{L-1} \mathbf{A}_k \mathbf{s}(n-k) \quad (3.6)$$

Donde \mathbf{A}_k es una matriz $M \times N$ representado los coeficientes de mezclado en el índice de retardo k . En el dominio de z , puede ser escrita como:

$$\mathbf{X}(z) = \mathbf{A}(z) \mathbf{S}(z) \quad (3.7)$$

Donde $\mathbf{A}(z) = \sum_{k=0}^{L-1} \mathbf{A}_k z^{-k}$ es una matriz de polinomios FIR y $z^{-k} s(n) = s(n - k)$.

La ecuación (3.7) describe una estructura llamada sistema lineal multicanal de múltiples entradas/múltiples salidas o MIMO (Multi-input/multi-output) con una respuesta impulso $\mathbf{A}(z)$. En la Figura 3.4 se representa un esquema de este modelo de mezclado para dos fuentes, el cual puede ser escrito como el siguiente sistema de ecuaciones lineales en el dominio de z .

$$\begin{aligned} X_1(z) &= A_{11}(z)S_1(z) + A_{12}(z)S_2(z) \\ X_2(z) &= A_{21}(z)S_1(z) + A_{22}(z)S_2(z) \end{aligned} \quad (3.8)$$




Figura 3.4. Modelo de mezclado convolutivo para las fuentes.

En esta estructura las mezclas $X_1(z)$ y $X_2(z)$ son formadas por las fuentes $S_1(z)$ y $S_2(z)$ filtradas por las respuestas impulsos:

$$\mathbf{A}(z) = \begin{bmatrix} A_{11}(z) & A_{12}(z) \\ A_{21}(z) & A_{22}(z) \end{bmatrix}$$

En la Figura 3.5 se muestra un ejemplo de un filtro $A_{12}(z) = 0.45z^6 + 0.2z^{10} + 0.05z^{13}$ para la estructura de la Figura 3.4. Este filtro tiene valores diferentes de cero en las muestras 6, 10 y 13. Si asumimos que el tiempo de llegada de la fuente s_1 al sensor x_1 como punto inicial de referencia o muestra cero, entonces el filtro $A_{12}(z)$ indica que copias de la fuente s_1 llega al sensor x_2 6, 10 y 13 muestras después, respectivamente, con una atenuación dada por el valor de magnitud del parámetro. Este retardo es debido a los múltiples caminos de propagación que la señal toma cuando es emitida por la fuente y que es reflejada varias veces antes de llegar al sensor. Es importante resaltar que la muestra 6 indica el TDOA de la fuente s_1 con respecto a los sensores x_1 y x_2 .




Figura 3.5. Ejemplo de un filtro h_{12} para una estructura de mezclado convolutivo de dos fuentes y dos mezclas.

3.3.2. Criterios para la búsqueda independencia estadística

El criterio de independencia nos ofrece una manera de medir que tan independiente son las estimaciones como resultado del algoritmo ICA. A medida que éste opera sobre las mezclas, se mide este grado de independencia. Sin embargo, se tiene que tomar en cuenta que la solución está restringida a los siguientes puntos:

- 1) Las fuentes que forman la mezcla deben ser estadísticamente independientes entre sí.
- 2) Los criterios de independencia para ICA se basan en la asunción que las fuentes originales que forman la mezclas tienen distribuciones no gaussianas. ICA sólo puede separar mezclas cuando hay como máximo una fuente gaussiana.
- 3) ICA no puede determinar las varianzas de las fuentes originales, debido a que los coeficientes de mezclado como las fuentes son desconocidas.
- 4) No es posible determinar el orden original en el cual las fuentes fueron mezcladas.
- 5) La matriz de mezclado debe ser cuadrada, lo que implica igual cantidad de mezclas y fuentes ($M = N$) donde el numero de mezclas M y el numero de fuentes N .

El punto 1) requiere que las fuentes sean independientes entre sí, es decir, que el conocimiento sobre una de las fuentes no proporcione información sobre la otra. Los procesos de generación de las señales de cada fuente no deben estar relacionados físicamente, lo que en la práctica es difícil de establecer y requiere tener un amplio conocimiento sobre la naturaleza de las fuentes para realizar esta asunción. El punto 2) tiene que ver con el concepto de fuente gaussiana. Este tipo de fuente está totalmente caracterizado al conocer su media y varianza, que son el primer y segundo orden estadístico, respectivamente. Cuando dos o más fuentes gaussianas son mezcladas y se aplica un método de decorrelación de segundo orden tal como Análisis de Componentes Principales o (PCA) las fuentes gaussianas son separadas, que es equivalente a buscar su mutua independencia. Una fuente no gaussiana, es caracterizada por Altos Ordenes Estadísticos o HOS (High Order Statistics), tales como la asimetría y la curtosis (tercero y cuarto orden estadístico, respectivamente). La aplicación de PCA no lleva a una separación de este tipo fuentes y es necesario aplicar un criterio de independencia que tome en cuenta los HOS, tales como la búsqueda la no gaussianidad o minimización de la mutua información (son explicados en las siguientes secciones). Sin embargo, los criterios de independencia basados en HOS no son diseñados para la separación de fuentes gaussianas. Solo pueden trabajar cuando hay como máximo una fuente gaussiana. Los puntos 3) y 4) presentan la indeterminación de ICA, que implica la imposibilidad de recuperar las varianzas (amplitudes originales) y medias de las fuentes, así como el orden en que fueron mezcladas. El punto 5) restringe la utilización de ICA a casos donde haya

igual cantidad de sensores y fuentes. En la práctica se asume este último punto, sin embargo, la posibilidad de más fuentes puede estar presente. Todas estas restricciones resaltan la importancia de un estudio exhaustivo sobre la naturaleza de las fuentes antes de aplicar algún algoritmo ICA.

Actualmente pueden ser identificadas dos algoritmos para ICA basados en los siguientes criterios de independencia ([Haykin, 2009](#)):

1. Maximización de la no gaussianidad: Algoritmo FastICA.
2. Minimización de la mutua información: Algoritmo de Amari, S., Cichocki A. y Yang.

3.3.2.1. Maximización de la no gaussianidad

Para comprender el proceso de maximización de la no gaussianidad se introduce primero el concepto de entropía diferencial de una variable aleatoria continua ξ :

$$h(v) = -\int_{-\infty}^{\infty} p(v) \log p(v) dv \quad (3.9)$$

Donde $p(v)$ es la función de distribución de probabilidad de v y $E[]$ es la esperanza estadística. La $p(v)$ y $h(v)$ tienen las siguientes propiedades:

1. $p(v) \geq 0$
2. $\int_{-\infty}^{\infty} p(v) dv = 1$
3. $h(v) \geq 0$

Las 1 y 2 son propiedades fundamentales de las funciones de densidad de probabilidad o PDF (Probability Density Function) y la 3 indica que la entropía diferencial siempre es no negativa. La entropía diferencial puede ser interpretada como el grado de información que se tiene sobre la variable v . Si $h(v) = 0$ indica que la variable s es totalmente determinística, o sea, que solo un valor de esta variable tiene un valor de probabilidad diferente de cero y los demás posibles valores tienen probabilidad cero. Si la variable tiene más valores con diferentes probabilidades, la variable se vuelve más aleatoria y su entropía diferencial aumenta.

De todas las variables aleatorias la que presentan la mayor entropía diferencial es una variable gaussiana ([Hyvarinen et al, 2001](#)). Muestran mayor incertidumbre y menos

estructura de la cual pueda ser inferida alguna información. Por otro lado, la entropía es baja para variables con PDF que están concentradas en ciertos valores, como las laplaciana, que tiene forma muy afilada o las uniformes, con forma plana.

Según el teorema del límite central si se suman variables independientes y no gaussianas, el resultado tiende a ser una mezcla que tiende a ser más gaussiana que las variables que la formaron ([Ross, 2004](#)). La mezcla resultante tiene una mayor entropía que los componentes que la formaron ya que es más gaussiana. Si se aplica un proceso que separe las mezclas en variables independientes guiado por la disminución de la entropía y que sea equivalente a buscar componentes no gaussianos esto llevará a recuperar las variables originales que formaron la mezcla. Aquí, es importante resaltar la importancia de la independencia y no gaussianidad de las fuentes. Si estos criterios no se cumplen no es posible aplicar el teorema y la búsqueda de la no gaussianidad de las fuentes. Para asegurar la no gaussianidad de las variables a recuperar se deben satisfacer dos propiedades ([Haykin, 2009](#)):

- 1) La medida de la no gaussianidad debe ser no negativa, asumiendo como límite inferior el valor de cero cuando sea una variable gaussiana.
- 2) Para todas las demás variables no gaussianas, la medida debe ser mayor de cero.

Una medida de la no gaussianidad que cumple con estas propiedades es la Negentropía. Esta medida compara la entropía diferencial de una variable gaussiana (variable de referencia) con la entropía diferencial de la variable a evaluar. La Negentropía de una variable aleatoria continua v esta definida como:

$$J(v) = h(v_{gauss}) - h(v) \quad (3.10)$$

Donde v_{gauss} es la variable gaussiana de referencia. La Negentropía es cero si la variable es gaussiana y mayor que cero de otro modo.

FastICA es el algoritmo más importante que utiliza la Negentropía como medida de independencia estadística para la recuperación de fuentes. Fue desarrollado en el Laboratorio de Información y Ciencias Computacionales de la Universidad Tecnológica de Helsinki, por Hugo Gvert, Jarmo Hurri, Jaakko Srel y Aapo Hyvarinen. Es de código abierto y es accesible a través de la página web ([ICA, 2016](#)). En FastICA se asume un modelo de mezclado lineal como el descrito por la ecuación (3.1) y utiliza un modelo de separación igual al descrito en la ecuación (3.2). FastICA utiliza una versión aproximada

para el cálculo de la Negentropía ya que la dada por la ecuación (3.10) es altamente demandante desde el punto de vista computacional, por lo que en ([Hyvarinen et al, 2001](#)) se propone la siguiente aproximación:

$$J(v) = E(\Phi(v)) - E(\Phi(v_{gauss}))^2 \quad (3.11)$$

Donde $E()$ es la esperanza estadística y $\Phi()$ es una función utilizada para aproximar la PDF de la variable v . v_{gauss} es una variable gaussiana con media cero y varianza unitaria y que es la variable de referencia para el cálculo de la Negentropía. La variable que evaluar v también debe tener su media cero y varianza unitaria.

FastICA presenta una regla de adaptación de pesos basada en la búsqueda de la no gaussianidad a través de la Negentropía dada por la ecuación (3.11) con el objetivo de estimar los componentes independientes que forman la mezcla. Esta regla es obtenida a partir de la maximización de la Negentropía con respecto a los pesos.

Antes de presentar esta regla introducen las siguientes consideraciones:

- 1) La ecuación (3.2), $\mathbf{y}(n) = \mathbf{W}\mathbf{x}(n)$ es cambiada a la siguiente forma

$$\mathbf{Y} = \mathbf{W}\mathbf{X} \quad (3.12)$$

Donde se ha remplazado la letra \mathbf{y} por \mathbf{U} y \mathbf{x} por \mathbf{X} para indicar que las observaciones y los componentes independientes tienen media cero y varianza unitaria. Se utiliza la matriz $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M]$ que está constituida por los vectores de observaciones \mathbf{x}_i , compuestos por todas sus muestras. De igual forma la matriz $\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_N]$ está compuesta por los componentes independientes \mathbf{u}_j compuestos de todas las muestras disponibles. Ejemplo: la observación $\mathbf{x}_1 = [x_1(1), x_1(2), \dots, x_1(T)]$ y el componente $\mathbf{u}_1 = [u_1(1), u_1(2), \dots, u_1(T)]$, donde cada vector es compuesto de T muestras.

- 2) En el cálculo de la Negentropía dado por la ecuación (3.11) en vez de utilizar una variable aleatoria continua v como argumento en FastICA se utilizan los vectores que representan a los componente independiente \mathbf{u}_j .
- 3) La esperanza $E()$ es la media de una cantidad T de muestras, ejemplo: $E(\mathbf{u}_1) = [u_1(1), u_1(2), \dots, u_1(T)]/T$.

- 4) La función $\Phi()$ es utilizada para aproximar la entropía diferencial de los componentes independientes \mathbf{u}_j y es escogida de manera tal que no crezca demasiado rápido con valores crecientes positivos o negativos de \mathbf{u}_j . En la Tabla 3.3 son mostradas tres ejemplos de funciones cuadráticas $\Phi()$ propuestas para el cálculo de la Negentropía y utilizadas por algoritmo FastICA.

Tabla 3.1. Lista de funciones para cálculo de la Negentropía. ξ representa el argumento de la función.

$\Phi(\xi)$	g	g'
$\log \cosh(\xi)$	$\tanh(\xi)$	$1 - \tanh(\xi)^2$
$-\exp(-\frac{\xi^2}{2})$	$\xi \exp(-\frac{\xi^2}{2})$	$(1 - \xi^2) \exp(-\frac{\xi^2}{2})$
ξ^4	ξ^3	ξ^2

Para obtener la regla de aprendizaje de los pesos hay que maximizar la Negentropía dada por (3.11). En este proceso se descarta el segundo término, ya que la variable gaussiana v_{gauss} no depende de los pesos. En FastICA no se utiliza toda la matriz de pesos \mathbf{W} sino un vector columna de pesos $\mathbf{w}_j = [w_{1j}, w_{2j}, \dots, w_{Mj}]^T$ que corresponde \mathbf{u}_j componente. De esta forma la maximización de la Negentropía con respecto al vector de pesos \mathbf{w}_j queda como.

$$\frac{\partial}{\partial \mathbf{w}_j} E(\Phi(\mathbf{u}_j)) = \frac{\partial}{\partial \mathbf{w}_j} E(\Phi(\mathbf{w}_j^T \mathbf{X})) \quad (3.13)$$

Esta maximización está sujeta a la restricción $\|\mathbf{w}_j\| = 1$, que significa que la Negentropía es maximizada, pero manteniendo la norma de los pesos \mathbf{w}_j unitaria. Como esta maximización tiene una restricción ($\|\mathbf{w}_j\|=1$) se utiliza el método de Lagrange. De esta manera, la ecuación (3.13) queda como ([Haykin, 2009](#)):

$$\frac{\partial}{\partial \mathbf{w}_j} E(\Phi(\mathbf{w}_j^T \mathbf{X})) - \lambda \mathbf{w}_j = 0 \quad (3.14)$$

Donde λ es el multiplicador de Lagrange. Al aplicar la derivada parcial a la ecuación (3.14) queda como:

$$E(\mathbf{x}g(\mathbf{w}_j^T \mathbf{X})) - \lambda \mathbf{w}_j = 0 \quad (3.15)$$

Donde $g()$ es la primera derivada de la función $\Phi()$ dadas en la Tabla 3.1

Para encontrar una regla de actualización de los pesos se aplica el método Newton ([Hyvarinen et al, 2001](#)), llegando a la siguiente regla:

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + E\{\mathbf{x}g(\mathbf{w}_j^T(t) \mathbf{X})\} - E\{g'(\mathbf{w}_j^T(t) \mathbf{X})\} \mathbf{w}_j(t) \quad (3.16)$$

Donde t indica el numero de iteración, \mathbf{w}_j es el j vector columna de la matriz \mathbf{W} que está asociado al \mathbf{u}_j componente independiente. Las funciones $g()$ y $g'()$ se aplican muestra a muestra. $g'()$ es la segunda derivada de la función $\Phi()$. En la Tabla 3.1 se muestran la primera g y segunda derivada g' de tres tipos de funciones $\Phi()$ que pueden ser utilizadas.

En la Figura 3.6 se muestra un ejemplo de cómo realiza la búsqueda de cada componente para el caso de una mezcla de tres fuentes. Primero a las observaciones $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3]^T$ se les extrae las medias y su varianza se hace unitaria. Posteriormente son multiplicadas por el vector de pesos $\mathbf{w}_1 = [w_{11}, w_{21}, w_{31}]^T$ produciendo el componente \mathbf{u}_1 el cual es utilizado para maximizar la Negentropía y actualizar los pesos \mathbf{w}_1 . Cabe destacar que este proceso se repite hasta que el algoritmo converge. El criterio de convergencia será explicado en la sección de métodos de optimización.




Figura 3.6. Proceso llevado a cabo por FastICA para la búsqueda de un componente independiente. Este ejemplo es para la búsqueda de un componente independiente dado tres mezclas.

Una vez que converge el algoritmo el vector de pesos encontrados corresponde al primer componente independiente \mathbf{u}_1 , el cual es el primer máximo de la negentropía. Para encontrar los siguientes componentes, utilizamos este mismo proceso, pero debemos asegurarnos de que no coincidamos con el peso previamente encontrado. Para lograr esto se hace un proceso llamado ortogonalización. Este proceso extrae de la mezcla el anterior componente independiente encontrado. En la Tabla 3.2 se muestran los pasos utilizados por el algoritmo FastICA estimar los componentes independientes.

Tabla 3.2. Pasos del algoritmo FastICA.

Numero de paso	Procedimiento
1	Hacer la media de \mathbf{X} cero y su varianza unitaria.
2	Escoger m , el número de componentes a estimar. Ajustar el contador de componentes a $j \leftarrow 1$
3	Escoger un valor inicial \mathbf{w}_j de manera aleatoria con norma unitaria.
4	Iniciar un contador de iteraciones t y guardar el vector de peso \mathbf{w}_j antes de la actualización de pesos

5	<p>Actualizar del vector de pesos por medio de la regla de aprendizaje</p> $\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + E\{\mathbf{x}g(\mathbf{w}_j^T(t)\mathbf{X})\} - E\{g'(\mathbf{w}_j^T(t)\mathbf{X})\}\mathbf{w}_j(t)$
6	<p>Hacer la siguiente ortogonalización:</p> $\mathbf{w}_j \leftarrow \mathbf{w}_j - \sum_{l=1}^{j-1} (\mathbf{w}_j^T \mathbf{w}_l) \mathbf{w}_l$
7	$\mathbf{w}_j \leftarrow \mathbf{w}_j / \ \mathbf{w}_j\ $
8	Si \mathbf{w}_j no converge volver al paso 5.
9	Ajustar $j \leftarrow j + 1$. Si $j \leq m$, regresar al paso

3.3.2.2. Minimización de la mutua información.

La mutua información es la medida de la información que una variable tiene sobre otra variable; es decir, cuanta información se obtiene de una variable si se posee información sobre otra. La mutua información para un conjunto de variables aleatorias continuas $\mathbf{v} = [v_1, v_2, \dots, v_M]$ está definida como ([Papoulis et al., 2002](#)):

$$I(v_1, v_2, \dots, v_M) = \sum_i^M h(v_i) - h(\mathbf{v}) \quad (3.17)$$

Donde $h(\mathbf{v}) = h(v_1, v_2, \dots, v_M)$ es la entropía diferencial conjunta de las variables v_i y $h(v_i)$ las entropías marginales de cada variable v_i .

Una propiedad importante de la mutua información es que es cero, $I(v_1, v_2, \dots, v_N) = 0$, si las variables v_i son mutuamente independientes. Esta propiedad es aprovechada en ICA donde se utiliza como criterio para la búsqueda de la independencia. Fue primero presentado en ([Comon, 1994](#)) donde se sugirió la utilización de una medida para la mutua información para evaluar que tan independiente son las salidas de modelo de separación de ICA, $\mathbf{y}(n) = \mathbf{W}\mathbf{x}(n)$. Esta medida, llamada la divergencia Kullback-Leibler (KL), indica cuan distante esta una PDF conjunta de las salidas $\mathbf{y}(n)$, $p(\mathbf{y}(n)) = p(y_1(n), y_2(n), \dots, y_N(n))$ y una de PDF conjunta de referencia, en las cuales las variables son mutuamente independientes. Si las salidas de $\mathbf{y}(n)$ son dependientes, la KL presenta un valor mayor de cero. En el caso contrario, si las salidas $\mathbf{y}(n)$ son mutuamente

independientes el valor de la KL es cero. La divergencia Kullback-Leibler (KL) está definida como ([Comon, 1994](#)):

$$K[p(\mathbf{y}(n)) \parallel p(\mathbf{s}(n))] = \int_{-\infty}^{\infty} p(\mathbf{y}(n)) \log \frac{p(\mathbf{y}(n))}{p(\mathbf{s}(n))} d\mathbf{y} \quad (3.18)$$

Donde $K[p(\mathbf{y}(n)) \parallel p(\mathbf{s}(n))]$ significa: divergencia KL entre la PDF conjunta de las salidas $\mathbf{y}(n)$ y una PDF conjunta de referencia.

El fundamento de la KL para ICA es la PDF de referencia. Comparando con el cálculo de la Negentropía, donde la referencia es una variable gaussiana, en la KL se utiliza como referencia una PDF conjunta de variables mutuamente independientes. Es claro que la referencia que se debe emplear es la PDF conjunta de las fuentes a estimar $p(\mathbf{s}(n))$, pues es el objetivo de ICA y son variables mutuamente independientes. Si aplicamos un proceso en el cual las salidas sean cambiadas hasta lograr que sean mutuamente independientes y $p(\mathbf{y}(n)) = p(\mathbf{s}(n))$ la KL será cero de la siguiente manera:

$$\begin{aligned} K[p(\mathbf{y}(n)) \parallel p(\mathbf{s}(n))] &= \int_{-\infty}^{\infty} p(y_1(n))p(y_2(n))\dots p(y_N(n)) \log \frac{p(y_1(n))p(y_2(n))\dots p(y_N(n))}{p(s_1(n))p(s_2(n))\dots p(s_N(n))} d\mathbf{y} \\ &= \int_{-\infty}^{\infty} p(y_1(n))p(y_2(n))\dots p(y_N(n)) \log(1) d\mathbf{y} \\ &= 0 \end{aligned}$$

Donde se han utilizado las siguientes sustituciones en (3.18):

$$p(\mathbf{s}(n)) = p(s_1(n), s_2(n), \dots, s_N(n)) = p(s_1(n))p(s_2(n)), \dots, p(s_N(n)),$$

$$p(\mathbf{y}(n)) = p(y_1(n), y_2(n), \dots, y_N(n)) = p(y_1(n))p(y_2(n)), \dots, p(y_N(n)),$$

Donde las PDF conjuntas $p(\mathbf{y}(n))$, $p(\mathbf{s}(n))$ pueden ser factorizadas en sus PDF marginales, si y solo si, las salidas $y_j(n)$ y las fuentes $s_j(n)$ son mutuamente independientes, respectivamente.

Para lograr este objetivo es necesario adaptar un parámetro relacionado a las salidas. En este caso son utilizados los pesos \mathbf{W} del modelo $\mathbf{y}(n) = \mathbf{W}\mathbf{x}(n)$. Estos deben ser adaptados enfocados en minimizar el valor de la KL.

Un problema que surge con este criterio de disminución de la mutua información es que para la separación ideal es necesario conocer a priori la PDF real de las fuentes $p(\mathbf{s}(n))$. Como solución, se puede estudiar el proceso físico asociado a las fuentes y

suponer una función de densidad. Se ha demostrado en ([Cichocki et al., 2002](#)) que con la asunción de una PDF cercana a la real de las fuentes se puede estimar una matriz de pesos **W** que todavía es un punto crítico de la KL. En la práctica, es suficiente con considerar dos tipos posibles de aproximaciones para $p(\mathbf{s}(n))$ ([Haykin, 2009](#)):

- 1) PDF de tipo supergaussiana, las cuales tiene una forma similar a la PDF laplaciana, que es definida por

$$p(s) = \frac{\alpha}{2} \exp(-\alpha|s|), \quad \text{para } -\infty \leq \alpha \leq \infty$$

En este tipo de distribución solo unos valores tienen la mayor probabilidad de ocurrir por lo que tiene una forma afilada en el origen como se observa en el ejemplo de la Figura 3.7.




Figura 3.7. Ejemplo de una PDF laplaciana de tipo supergaussiana. Éstas presentan la probabilidad concentrada en para algunos valores, lo que les da forma afilada. U.A. significa Unidades Arbitrarias.

- 2) PDF de tipo subgaussiana, las cuales tienden a presentar muchos valores con parecida probabilidad lo que les da una forma plana en el origen, tal como una distribución de probabilidad uniforme en el ejemplo mostrado en Figura 3.8.




Figura 3.8. PDF uniforme de tipo subgaussiana. En este ejemplo los valores en amplitud de -1 a 1 presentan igual probabilidad. Esto le da forma plana. U.A. significa Unidades Arbitrarias.

La minimización de la mutua información por medio de la KL es un proceso iterativo en el cual se adapta la matriz de pesos \mathbf{W} . Esta adaptación se realiza por medio de una regla de aprendizaje para los pesos, en la cual se toman en cuenta algunas consideraciones:

Se reemplaza la PDF conjunta de las fuentes por una aproximación (PDF supergaussiana o subgaussiana), $(q(\mathbf{y}(n)) \approx p(\mathbf{s}(n)))$, donde $q(\mathbf{y}(n))$ es la PDF conjunta de variables independientes asumida para las fuentes. Estas variables son mutuamente independientes y puede ser factorizada en sus PDF marginales, $q(\mathbf{y}(n)) = q(y_1(n))q(y_2(n)), \dots, q(y_N(n)) = \prod_j^N q(y_j(n))$. Al sustituir esta aproximación en la ecuación (3.18) para la KL queda como:

$$K[p(\mathbf{y}(n)) \parallel q(\mathbf{y}(n))] = \int_{-\infty}^{\infty} p(\mathbf{y}(n)) \log \frac{p(\mathbf{y}(n))}{\prod_j^N q(y_j(n))} d\mathbf{y} \quad (3.19)$$

Para encontrar una regla de aprendizaje, la KL se expresa en una forma más manejable, la cual es en término de las entropías conjunta de las salidas y las aproximaciones de las fuentes:

$$\begin{aligned}
K[p(\mathbf{y}(n)) \| q(\mathbf{y}(n))] &= \int_{-\infty}^{\infty} p(\mathbf{y}(n)) \log p(\mathbf{y}(n)) d\mathbf{y} - \int_{-\infty}^{\infty} p(\mathbf{y}(n)) \log \prod_j^N q(y_j) d\mathbf{y} \\
&= -h(\mathbf{y}(n)) + \sum_i^N \int_{-\infty}^{\infty} p(\mathbf{y}(n)) \log q(y_j(n)) d\mathbf{y} \\
&= -h(\mathbf{y}(n)) + \sum_j^N h(\tilde{y}_j(n))
\end{aligned} \tag{3.20}$$

Donde se utiliza las siguientes definiciones:

$h(\mathbf{y}(n)) = -\int_{-\infty}^{\infty} p(\mathbf{y}(n)) \log p(\mathbf{y}(n)) d\mathbf{y}$ es la entropía conjunta del vector de salidas $\mathbf{y}(n)$.

$h(\tilde{y}_j(n)) = -\int_{-\infty}^{\infty} p(y_j(n)) \log q(y_j(n)) dy_j$. Es la entropía de las fuentes asumidas.

Si se reemplaza $\mathbf{y} = \mathbf{W}\mathbf{x}$ en (3.20) se obtiene la siguiente ecuación para la KL entre la PDF de las salidas y la PDF de referencia (fuentes) ([Haykin, 2009](#)):

$$K[p(\mathbf{y}(n)) \| q(\mathbf{y}(n))] = -h(\mathbf{x}(n)) - \log |\det(\mathbf{W})| + \sum_j^N h(\tilde{y}_j(n)) \tag{3.21}$$

Donde $h(\mathbf{y}(n)) = h(\mathbf{x}(n)) + \log |\det(\mathbf{W})|$, $\det(\mathbf{W})$ es el determinante de la matriz de pesos \mathbf{W} y $H(\mathbf{x}) = -\int_{-\infty}^{\infty} p(\mathbf{x}) \log p(\mathbf{x}) d\mathbf{x}$ es la entropía conjunta de las mezclas $\mathbf{x}(n)$ la cual no depende de los pesos \mathbf{W} . Esta ultima se puede omitir de la ecuación (3.21):

$$K[p(\mathbf{y}(n)) \| q(\mathbf{y}(n))] = -\log |\det(\mathbf{W})| + \sum_j^N h(\tilde{y}_j(n)) \tag{3.22}$$

Las entropías marginales $h(\tilde{y}_j(n))$ pueden ser reemplazadas por sus esperanzas

$h(\tilde{y}_j(n)) = -E \left(\log \left(q(y_j(n)) \right) \right)$, y de esta manera la KL queda como:

$$K[p(\mathbf{y}(n)) \| q(\mathbf{y}(n))] = -\log |\det(\mathbf{W})| - \sum_j^N E(\log(q(y_j(n)))) \tag{3.23}$$

La ecuación (3.23) define la KL en términos de los pesos \mathbf{W} y la PDF asumida para las fuentes. Esta ecuación puede ser minimizada con respecto a los pesos y de esta manera

encontrar una regla de aprendizaje que permita disminuir la mutua información de $\mathbf{y}(n)$ y hacer sus componentes mutuamente independientes. Esta regla fue introducida por Amari, S., Cichocki A. y Yang en ([Amari et al., 1996](#)) como parte de un algoritmo ICA para resolver BSS. De aquí en adelante lo llamaremos algoritmo ICA-Amari.

A diferencia de FastICA que utiliza optimización por Newton y que necesita un bloque de datos para estimar los pesos, la optimización con el algoritmo Amari emplea el gradiente descendiente estocástico que es una versión instantánea del gradiente descendiente. Una versión instantánea significa, que la regla de aprendizaje adapta los pesos con una sola muestra a la vez por componente. Esta estrategia permite un algoritmo que se adapta a los cambios en el tiempo que puede sufrir la fuente. Esta versión también es conocida como en línea u online (en inglés).

El gradiente descendiente estocástico es definido como:

$$\Delta \mathbf{W} = \mathbf{W}(t+1) - \mathbf{W}(t) = -\eta(t) \frac{\partial \rho(\mathbf{W})}{\partial \mathbf{W}} \quad (3.24)$$

Donde t es el índice de la iteración actual, $\eta(t)$ es la tasa de aprendizaje que depende de t y representa el tamaño del paso del gradiente descendiente estocástico en la dirección negativa. En la ecuación (3.24) ha remplazado la $K[p(\mathbf{y}(n))||q(\mathbf{y}(n))]$ por su versión online $\rho(\mathbf{W})$. Esta es definida como:

$$\rho(\mathbf{W}) = -\log|\det(\mathbf{W})| - \sum_j^N \log(p(\tilde{y}_j(n))) \quad (3.25)$$

Note que para calcular la KL no se emplea la esperanza $E()$ sino una versión que utiliza una muestra en un tiempo n para cada componente $\tilde{y}_j(n)$. Diferenciando (3.25):

$$\frac{\partial \rho(\mathbf{W})}{\partial \mathbf{W}} = -\frac{\partial \log|\det(\mathbf{W})|}{\partial \mathbf{W}} - \frac{\partial \sum_j^N \log(p(\tilde{y}_j(n)))}{\partial \mathbf{W}} \quad (3.26)$$

El primer término del lado derecho de la ecuación (3.26) es definido como ([Haykin, 2009](#)):

$$\frac{\partial}{\partial \mathbf{W}} \log |\det(\mathbf{W})| = \mathbf{W}^{-T} \quad (3.27)$$

Donde \mathbf{W}^{-T} es la transpuesta de la matriz inversa \mathbf{W}^{-1} . El segundo término es definido como ([Haykin, 2009](#)):

$$\frac{\partial}{\partial \mathbf{W}} \sum_j^N \log(p(\tilde{y}_j(n))) = -\boldsymbol{\varphi}(\mathbf{y}(n))\mathbf{x}^T(n) \quad (3.28)$$

Donde $\boldsymbol{\varphi}(\mathbf{y}(n)) = [\varphi(y_1(n)), \varphi(y_2(n)), \dots, \varphi(y_N(n))]^T$ se le conoce como función de activación y fue introducida en ([Bell et al., 1995](#)). Se utiliza para aproximar la PDF asumida para las fuentes $q(\mathbf{y}(n))$ a medida que el algoritmo converge. Note que el termino $\tilde{y}_j(n)$ utilizado para expresar las fuentes asumidas, es reemplazado por las salidas $y_j(n)$.

En la Tabla 3.3 se presentan varias PDF y su respectiva función de activación. Como normalmente se asume que las fuentes $\mathbf{s}(n)$ a estimar tienen media cero y varianza unitaria, el valor $\sigma = 1$. De todas las PDF de la tabla, solo la PDF gaussiana generalizada puede ser utilizada para PDF subgaussianas, con valores de $r > 2$.

Reemplazando los términos (3.27) y (3.28) en (3.24) obtenemos el cambio de los pesos para minimización de la KL:

$$\Delta \mathbf{W} = \eta(t)(\mathbf{W}^{-T} - \boldsymbol{\varphi}(\mathbf{y}(n))\mathbf{x}^T(n)) \quad (3.29)$$

La regla de aprendizaje se obtiene al calcular el peso de la iteración $t + 1$ siguiente forma:

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \eta(t)(\mathbf{W}^{-T} - \boldsymbol{\varphi}(\mathbf{y}(n))\mathbf{x}^T(n)) \quad (3.30)$$

En la regla de aprendizaje dada por la ecuación (3.30) el término \mathbf{W}^{-T} implica la inversión de una matriz lo que puede dar inestabilidad al algoritmo además de incrementar el tiempo de convergencia. El gradiente descendiente representa la minimización de la KL con respecto a los pesos en un espacio euclidiano, lo que implica la búsqueda de una matriz de pesos no singular \mathbf{W} . En ([Amari et al., 1996](#)) se explota este hecho y se introduce una métrica Riemanniana al espacio de los pesos \mathbf{W} , la cual es representada por

el gradiente natural, que implica multiplicar el gradiente descendiente por el producto $\mathbf{W}^T \mathbf{W}$:

$$-\frac{\partial \rho(\mathbf{W})}{\partial \mathbf{W}} \mathbf{W}^T \mathbf{W} = [\mathbf{I} - \boldsymbol{\phi}(\mathbf{y}(n)) \mathbf{y}^T(n)] \mathbf{W} \quad (3.31)$$

Con el gradiente natural se elimina el problema de la inversión de la matriz \mathbf{W} dejando la regla de aprendizaje con la siguiente forma:

$$\mathbf{W}(t+1) = \mathbf{W}(t) + \eta [\mathbf{I} - \boldsymbol{\phi}(\mathbf{y}(n)) \mathbf{y}^T(n)] \mathbf{W}(t) \quad (3.32)$$

Donde \mathbf{I} es una matriz identidad.

Tabla 3.3. Funciones de densidad de probabilidad y sus funciones de activacion, respectivamente. El simbolo σ se refiera a la varianza de la señal.

Nombre	Función de distribución de probabilidad $q(y_i)$	Función de activación $\phi(y)$
Gaussiana	$\frac{1}{\sqrt{2\pi\sigma}} \exp(-\frac{ y_i ^2}{2\sigma^2})$	$\frac{u}{\sigma}$
Laplaciana	$\frac{1}{2\sigma} \exp(-\frac{ y_i }{\sigma})$	$\frac{\text{Sign}(u)}{\sigma}$
Cauchy	$\frac{1}{\pi\sigma} \frac{1}{1+(y_i/\sigma)^2}$	$\frac{2u}{\sigma^2 + u^2}$
Coseno Hiperbólico	$\frac{1}{\pi \cosh(y_i/\sigma^2)}$	$\tanh(u/\sigma^2)$
Sigmoidal	$\frac{\exp(-y_i/\sigma)}{(1+\exp(-y_i/\sigma))^2}$	$1 - \frac{2}{1+\exp(-u/\sigma)}$
Tangente Hiperbólico	$1 - \tanh(y_i/\sigma^2)$	$2 \tanh(u/\sigma)$
Gaussiana generalizada	$\frac{r}{2\sigma\Gamma(1/r)} \exp(-\frac{1}{r} \left \frac{y_i}{\sigma} \right ^r)$	$\frac{ u ^{r-1}}{\sigma^r} \text{Sign}(u)$

En la Tabla 3.4 se muestra los pasos del algoritmo ICA-Amari. Existen cuatro parámetros necesarios para iniciar el proceso de separación: función de activación $\phi()$, la tasa de aprendizaje η , el número de iteraciones it y la matriz \mathbf{W} . La función de

activación está relacionada con la densidad de distribución estadística del proceso que genera las señales y se debe realizar un estudio sobre el mismo para escogerla. La tasa de aprendizaje normalmente se inicia con valores menores a la unidad. Si se utilizan valores cercanos a la unidad el algoritmo converge más rápido, pero es inestable; si se emplean valores más pequeños el algoritmo converge en forma más lenta pero estable. En la escogencia de la tasa de aprendizaje existe un compromiso entre la estabilidad versus la velocidad de convergencia.

El número de iteraciones es la cantidad de actualizaciones que sufren los pesos de la matriz \mathbf{W} . En algunos casos el algoritmo converge antes de alcanzar este número de iteraciones. Para no gastar tiempo innecesario se utiliza un criterio de parada δ basado en el cambio de los pesos. A medida que el algoritmo minimiza la mutua información entre las salidas, los pesos tienden estabilizarse. En este caso, se almacena el valor de los pesos de la última iteración y se compara con el valor actual de los pesos. Esta comparación es realizada calculando la norma de la diferencia entre el valor anterior y actual de los pesos. Si la diferencia es menor que un valor de referencia, por ejemplo: $\delta = 10^{-3}$, el algoritmo es detenido, donde utilizamos δ como símbolo para darle nombre a la condición de parada.

Tabla 3.4. Algoritmo ICA-Amari.

Numero de paso	Procedimiento
1	Escoger los parámetros del algoritmo: función de activación $\varphi()$, tasa de aprendizaje η y numero de iteraciones it .
2	Escoger un bloque T de muestras desde las medidas.
3	Iniciar la matriz \mathbf{W} con valores aleatorios.
4	Aplicar $\mathbf{y}(n) = \mathbf{W}\mathbf{x}(n)$ al bloque de muestras.
5	Utilizar para actualizar los pesos de la matriz \mathbf{W} .
6	Repetir los pasos 4 y 5 hasta que el algoritmo alcance el número de iteraciones escogido o el criterio de parada δ .

3.4. Separación de mezclas convolutivas

El modelo lineal $\mathbf{y}(n) = \mathbf{W}\mathbf{x}(n)$ trata con fuentes mezcladas instantáneamente. Sin embargo, en este trabajo, el objetivo es la separación de señales en ambiente reales en el éstas son afectadas por el medio y modeladas por $\mathbf{X}(z) = \mathbf{A}(z)\mathbf{S}(z)$, donde $\mathbf{S}(z)$ son las fuentes originales en el dominio de z . Como se introdujo en la sección 3.3.1 las

observaciones desde los sensores $\mathbf{X}(z)$ pueden contener múltiples replicas atenuadas y retardadas de las fuentes debido a reflexiones en diversos objetos como paredes, pisos u otros objetos. Este efecto que sufren las emisiones el cual es conocido como reverberación, introduce ecos y distorsiones espectrales en la forma de onda de las fuentes. Este proceso es conocido como mezclado convolutivo y es modelado para dos fuentes por la ecuación (3.8):

$$\begin{aligned} X_1(z) &= A_{11}(z)S_1(z) + A_{12}(z)S_2(z) \\ X_2(z) &= A_{21}(z)S_1(z) + A_{22}(z)S_2(z) \end{aligned}$$

Los algoritmos FastICA e ICA-Amari, descritos previamente, tratan con mezclas instantáneas, por lo que es necesario adaptarlos para tratar con mezclas convolutivas. Para el caso de FastICA, hasta la fecha no existe una extensión para tratar con mezclas convolutivas. En el caso del algoritmo ICA-Amari existe una extensión propuesta en ([Choi et al., 2002](#)) para tratar con este tipo de mezclas. En las siguientes secciones presentaremos los detalles de este algoritmo el cual se utiliza en esta tesis para tratar con el problema de mezclado en ambientes de múltiples fuentes de DP.

3.4.1. Algoritmo de ICA para separación de mezclas convolutivas

Para resolver el problema de mezclado convolutivo en ([Choi et al., 2002](#)) se propone una solución basada en una estructura de separación con realimentación. En la Figura 3.9 se muestra esta estructura para dos fuentes y dos mezclas la cual puede escribirse como:

$$\begin{aligned} Y_1(z) &= X_1(z) + W_{12}(z)Y_2(z) \\ Y_2(z) &= X_2(z) + W_{21}(z)Y_1(z) \end{aligned} \tag{3.33}$$

La estructura realiza la separación de la siguiente manera: inicialmente $X_1(z)$ contiene versiones filtradas de las dos fuentes originales, $S_1(z)$ y $S_2(z)$ (ver ecuación (3.8)). En operación, se toma el resultado de la convolución $W_{12}(z)Y_2(z)$ y se le resta a $X_1(z)$. En un proceso de optimización (explicado más adelante) el peso W_{12} es ajustado de tal manera que tiende a $-A_{12}(z)$ lo que permite restar $Y_2(z)$ de la mezcla $X_1(z)$. Similarmente el valor $W_{21}(z)Y_1(z)$ elimina la fuente $S_1(z)$ de la mezcla $X_2(z)$. En este caso $W_{21}(z)$ tiende a $-A_{21}(z)$. El resultado final es $Y_1(z) = A_{11}(z)S_1(z)$ y $Y_2(z) =$

$A_{22}(z)S_2(z)$, donde se ha eliminado la mutua interferencia entre las fuentes $S_1(z)$ y $S_2(z)$. Las señales $Y_1(z)$ y $Y_2(z)$ representan las emisiones de las fuentes sin interferencias de otras fuentes. Es decir, como si estuvieran activas en solitario.

El conjunto de ecuaciones (3.33) puede ser escrito en el dominio del tiempo como:

$$\mathbf{y}(n) = \mathbf{x}(n) + \sum_{k=0}^{L-1} \mathbf{W}_k \mathbf{y}(n-k) \quad (3.34)$$

donde L es la longitud de los filtros FIR dado por las matrices $N \times M$ de pesos \mathbf{W}_k y las salidas $\mathbf{y}(n) = [y_1(n), \dots, y_N(n)]^T$. La longitud de los filtros L es finita y depende de la distancia de propagación considerada.




Figura 3.9. Modelo de estructura de separación y estimación de fuentes.

Para obtener los pesos \mathbf{W}_k se utiliza un criterio de independencia basado en la minimización de la mutua información similar al utilizado por el algoritmo de Amari para mezclas simultáneas con la diferencia que ahora las mezclas son convolutivas. En este caso la regla de aprendizaje para los pesos es:

$$\mathbf{W}_k(t) = \mathbf{W}_k(t-1) - \eta [\mathbf{I} - \mathbf{W}_0(t)] \left[\boldsymbol{\phi}(\mathbf{y}(n)) \mathbf{y}(n-k)^T \right] \quad (3.35)$$

Donde \mathbf{I} es la matriz identidad, $\eta > 0$ es la tasa de aprendizaje, $\boldsymbol{\phi}(\mathbf{y}) = [\phi_1(y_1) \phi_2(y_2) \dots \phi_N(y_N)]^T$, es una función no lineal que actúa elemento a elemento y es seleccionada de acuerdo a la función de densidad de probabilidad de las fuentes (ver Tabla 3.3).

En la Tabla 3.5 son mostrados los pasos para aplicar el algoritmo Amari para mezclado convolutivo. Primero son escogidos los parámetros del algoritmo: La función

de activación $\varphi()$, la cual depende de la distribución de probabilidad de las fuentes; la longitud de los filtros L que toma en cuenta los retardos de las señales que llegan a los sensores; la tasa de aprendizaje η , la cual es escogida empíricamente. El último parámetro del algoritmo es el número de iteraciones.

Una vez establecido los parámetros del algoritmo se escoge bloque T de muestras, lo que constituye un matriz de tamaño $N \times T$. Estas muestras son tomadas una a una y calculada una salida $\mathbf{y}(n)$ muestra a muestra con la ecuación (3.34). Para el algoritmo se utilizan L matrices \mathbf{W}_k de tamaño $N \times N$. Para el caso de dos fuentes y dos mezclas, o $N = 2$ y $M = 2$; los pesos son representados en una matriz:

$$\mathbf{W}_k = \begin{bmatrix} 0 & w_{12k} \\ w_{21k} & 0 \end{bmatrix}, \text{ para } k = 0, 1, \dots, L-1; \quad (3.36)$$

Los pesos también pueden ser expresados de manera vectorial como $\mathbf{w}_{12} = [w_{120}, w_{121}, \dots, w_{12L-1}]$ y $\mathbf{w}_{21} = [w_{210}, w_{211}, \dots, w_{21L-1}]$.

Todas estas matrices son inicializadas con sus elementos iguales a cero, excepto para la matriz \mathbf{W}_0 en la cual los elementos fuera de la diagonal principal son ajustados a uno de la siguiente manera:

$$\mathbf{W}_0 = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}.$$

Es importante resaltar que la separación ideal implica que los pesos $\mathbf{w}_{12} = -\mathbf{h}_{21}$ y $\mathbf{w}_{21} = -\mathbf{h}_{12}$. Como fue presentado en la sección 3.4.1 en los pesos \mathbf{h}_{12} y \mathbf{h}_{21} se encuentra información relativa a los TDOA de las fuentes, s_1 y s_2 . Esta información se utiliza en esta tesis como base para un método de estimación de TDAO en un ambiente de múltiples fuentes que será presentado en los capítulos 4 y 5.

Tabla 3.5. Algoritmo Amari para mezclado convolutivo.

Numero de paso	Procedimiento
1	Escoger los parámetros del algoritmo: función de activación $\varphi()$, longitud del filtro L , tasa de aprendizaje η y numero de iteraciones it .
2	Escoger un bloque T de muestras desde las medidas.
3	Iniciar las matrices $\mathbf{W}_k = \mathbf{0}$, ($k = 0, 1, \dots, L-1$); la matriz \mathbf{W}_0 ajustar a cero excepto los elementos fuera de la diagonal principal, los cuales deben ser iniciados con unos.

4	Aplicar (3.34) al bloque de muestras.
5	Utilizar (3.35) para actualizar los pesos de las matrices \mathbf{W}_k , (3.36).
6	Repetir los pasos 4 y 5 hasta que el algoritmo alcance el número de iteraciones escogido o el criterio de parada δ

3.5. Conclusiones del capítulo

En este capítulo se ha presentado BSS para tratar el problema de mezclado debido a la presencia de múltiples fuentes activas. En el marco de BSS, ICA se propone como enfoque para resolver este problema asumiendo la independencia estadística de las fuentes. El tratamiento matemático general manejado en BSS e ICA ofrece la posibilidad de emplearlos con señales generadas por diferentes tipos de procesos, desde acústicos, eléctricos hasta electromagnéticos, por lo que posibilita aplicarlo al área de descargas parciales. Además, se introducen los dos algoritmos más famosos para el caso de mezclado simultáneo: FastICA y el algoritmo ICA-Amari. En FastICA se utiliza la Negentropía como medida de la independencia estadística y la divergencia KL para el caso de Amari.

En un ambiente real, cuando las señales son emitidas sufren reflexiones y atenuación al propagarse. En el caso de múltiples fuentes estas señales se mezclan en un proceso convolutivo. Para resolver este problema, se introduce un algoritmo basado en el de Amari, pero adaptado para tratar con mezclas convolutivas. Este algoritmo presenta una estructura de realimentación que le da la capacidad de eliminar la mutua interferencia entre las diferentes fuentes. Este algoritmo es el escogido en esta tesis para enfrentar el problema de mezclado de múltiples fuentes de DP. En los capítulos 4 y 5 se diseñan y realizan experimentos que generan mezclas que son procesadas por este algoritmo con el objetivo de separarlas y posibilitar la identificación y localización de las fuentes de DP.

CAPÍTULO 4

4. Identificación y localización de múltiples DP con ICA

En las tareas de identificación y localización de fuentes de DP se cuentan con la detección de las señales gracias a sensores instalados en el equipo donde se sospecha que existe la actividad. Los métodos de identificación presentados en el capítulo 2 normalmente asumen la presencia de una fuente, sin embargo, siempre existe la posibilidad de más de una fuente emitiendo señales que se mezclan en cada sensor. En este caso las señales desde distintas fuentes pueden llegar a solaparse e interferirse distorsionando el contenido de información importante para la identificación y localización.

Como ha sido presentado en el capítulo anterior, existe un algoritmo basado en ICA que es una versión del algoritmo ICA-Amari para mezclas instantáneas, pero adaptada para tratar con mezclas convolutivas. De esta separación, el resultado son estimaciones de las señales fuentes sin interferencia de las otras. En este capítulo se aplicará el algoritmo ICA-Amari para mezclas convolutivas para separar, identificar y localizar múltiples DP utilizando el método de detección acústica. El resultado será analizado con el objetivo de evaluar su potencial como herramienta para la identificación de las DP. Además, se utilizará información contenida en los pesos estimados por el algoritmo ICA-Amari para obtener los TDOA con el objetivo de localizar las fuentes. En este capítulo, por simplicidad, llamaremos a la extensión para mezclas convolutivas de algoritmo ICA-Amari sólo algoritmo ICA-Amari. Es importante esta aclaración para no confundir con el algoritmo de Amari aplicado a mezclas instantáneas.

4.1. ICA para separación de señales acústicas de DP.

ICA está sustentado en una sólida teoría matemática y estadística y que ha sido desarrollada específicamente para solucionar el problema de mezclado de señales en

ambiente reales. Además, es transparente al tipo de señales que procesa; es decir, no es afectado por las características particulares de un proceso, sólo es necesario que sean estadísticamente independientes, lo que ofrece un marco general para trabajar con todo tipo de señales. Los defectos que generan las señales de DP son de naturaleza estocásticas ([Heinz et al., 1999](#), [Okamoto et al., 2001](#)) por lo que dos o más defectos localizados en diferentes puntos espaciales no tienen ninguna correlación y son mutuamente independientes. Esta condición es primordial para la aplicación del algoritmo ICA-Amari i y es asumida en las pruebas experimentales en los siguientes capítulos.

En las siguientes secciones son realizadas experimentos para evaluar la efectividad del algoritmo para realizar la separación de mezclas de señales acústicas desde múltiples fuentes de DP y posibilitar la identificación de dos tipos de descargas. Los experimentos son desarrollados en dos etapas:

- Simulación: Se crean mezclas sintéticas a partir de señales emitidas por fuentes de DP reales. La simulación es realizada en un programa creado en MATLAB donde se aplica el algoritmo Amari y se realiza la identificación.

- Banco de ensayos: A través de un banco de ensayos se generan señales acústicas reales emitidas desde fuentes simuladas de DP. Por medio de sensores de emisiones acústicas las señales resultantes son detectadas y registradas para luego ser procesadas por el algoritmo.

Además de la identificación, en los experimentos se analizan la influencia de los parámetros operativos del algoritmo: tasa de aprendizaje, longitud de los filtros, número de iteraciones y valores iniciales de pesos.

4.2. Señales de DP para los experimentos

En los experimentos se utilizan señales acústicas emitidas por fuentes reales de DP y sirven de referencia para caracterizar las señales fuentes generadas en el banco de ensayos. Las señales fueron obtenidas desde un experimento desarrollado en el Laboratorio de Alta Tensión (LINEALT) de la Universidad Carlos III de Madrid ([Posada-Román et al., 2012](#), [Rubio-Serrano et al., 2012](#)). En estos experimentos se utilizó el método acústico para detectar las emisiones desde las fuentes de descarga de modelos de defectos para generar DP internas y superficiales.

Para generar las descargas internas se utilizaron dos electrodos circulares planos de 7.5 cm de diámetro con en los cuales se colocaba en medio 8 capas de 0.1 mm de papel impregnado con aceite mineral como se muestran en la Figura 4.1 (a). En medio de las capas de papel se forman cavidades microscópicas donde se generan DP internas. Las descargas superficiales son generadas por un arreglo de aguja-plano como se muestra en la Figura 4.1(b). Es compuesto por una aguja, un aislante de 16 capas de papel impregnadas de aceite y un electrodo. En la Figura 4.2 se muestra el experimento en la que se pueden apreciar las dos fuentes de descargas parciales inmersas en una cuba llena de aceite y un único sensor de emisiones acústicas ubicado en las paredes del objeto de ensayo. El sensor estaba directamente en frente y colocado a 12.5 centímetros de cada fuente cuando se realizaba la medición.




Figura 4.1. Esquemas para generar DP: (a) Internas, y (b) Superficiales ([Rubio-Serrano et al., 2012](#)).




Figura 4.2. Se muestra las dos fuentes de DP: Superficial e Interna, el sensor de emisiones acústicas (EA) y el tanque con el aceite del transformador.

Las señales acústicas de cada tipo de fuente de DP se detectaron de manera aislada para evitar cualquiera interferencia entre ellas; es decir, primero se aplicó tensión únicamente a la fuente de PD superficiales y se registraron las formas de onda de las emisiones acústicas en el sensor y de igual manera para registrar las señales acústicas desde las fuentes internas. Cada señal está compuesta por 500 muestras y fueron registradas con una velocidad de muestreo de 1 MHz. El resultado son señales acústicas de DP internas y superficiales, que se utilizan como referencias de cada tipo de fuente. Para cada tipo de DP se grabaron 25 señales. En la Figura 4.3 se muestra un ejemplo típico de la forma de onda una señal acústica de DP interna. Esta señal tiene una duración $25 \mu\text{s}$ y 22mV pico a pico. En la Figura 4.3 se muestra la densidad de potencia espectral de esta señal, la cual tiene la mayor parte de su energía entre 75kHz y 170kHz.




Figura 4.3. a) Ejemplo de una de las EA desde una fuente de DP interna, y b) su densidad de potencia espectral.

En la Figura 4.4 se muestra la forma de onda de una señal acústica de DP superficial. Consta de aproximadamente once oscilaciones aumenta repentinamente al inicio y después cae lentamente. Su duración total es de unos de $60 \mu\text{s}$ y con 55 mV pico a pico. La densidad de potencia espectral se muestra en la Figura 4.4 b) con una zona de varios picos de energía entre los 75kHz a los 250 kHz un máximo de energía en 155kHz a -80dB y otro en los 230 kHz aproximadamente.




Figura 4.4. a) Ejemplo de una de las EA desde una fuente de DP superficial, y b) su densidad de potencia espectral.

Tanto en su forma de onda como en su espectro los dos tipos de DP son diferentes. Una manera fácil y compacta de evaluar esta diferencia es realizando una descomposición Wavelet y obteniendo la huella de energía de cada tipo (Ver la sección 2.4.2 para más detalles). Para realizar la descomposición es utilizada la Wavelet madre Daubechies 20 con una descomposición de 4 niveles que cubre un rango que va desde los 42kHz a los 667 kHz. En la Tabla 4.1 se muestran el rango de frecuencia que corresponde a cada nivel. La descomposición y extracción de la huella de energía se aplicó al conjunto de 25 señales por cada tipo. En la Figura 4.5 se presenta el valor promedio de energía de este conjunto de señales, así como la desviación estándar lo cual dio un valor de 5%.

Tabla 4.1. Rangos de frecuencias correspondientes a cada nivel de descomposición Wavelet

Nivel	Rango de frecuencia (kHz)
1	667-333
2	333-167
3	167-83
4	83-42

De este análisis Wavelet se puede concluir que las señales acústicas desde la fuente DP interna contiene más del 90 % de la energía en los niveles 2 y 3 correspondiente a un rango de frecuencia desde los 83kHz a los 333kHz, mientras que las señales acústicas desde la fuente de DP superficial presenta más del 80% de la energía en la banda 2 correspondiente a un rango de frecuencia de 167 kHz a 333kHz. Los correspondientes

valores de energía por banda pueden ser empleados como un patrón representativo para cada señal y para diferenciarlos cuantitativamente.




Figura 4.5. Distribución promedio de energía por para cada nivel de descomposición Wavelet para cada grupo de 25 señales acústicas desde las fuentes DP internas y superficiales. La desviación estándar para cada nivel es mostrada en negro.

4.3. Identificación utilizando mezclas sintéticas

Los conjuntos de 25 señales de cada tipo se utilizan para realizar simulaciones de mezclas con el objetivo de aplicarlas al algoritmo ICA-Amari. Para simular la posición espacial de las fuentes se utiliza el esquema de la Figura 4.6 como referencia, el cual simula de manera básica el tanque de un transformador. Se asume la presencia de dos fuentes de DP, s_1 y s_2 , como una DP interna y una superficial, respectivamente. Los sensores x_1 y x_2 simulan los sensores acústicos. Es importante anotar que un criterio para el buen funcionamiento del algoritmo es la presencia de igual cantidad de fuentes y sensores.

Las coordenadas de las fuentes s_1 y s_2 son colocadas en (0,30) y (10,30), respectivamente; el sensor x_1 es fijado como el origen (0,0) del sistema de coordenadas y el sensor x_2 en (10,0). Todas estas dimensiones están en centímetros. Estas posiciones son elegidas de tal manera que las señales emitidas se superponen en los sensores.

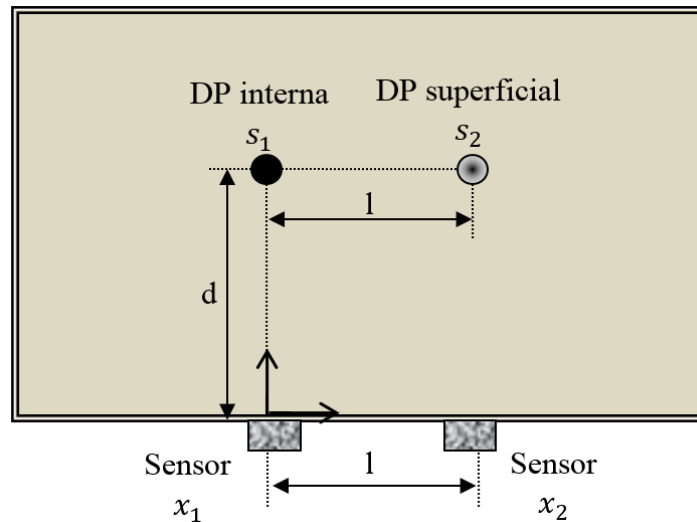


Figura 4.6. Vista de planta del tanque con aceite donde esta localizadas de las fuentes (interna y superficial) y los sensores para la simulación. Las fuentes están a 30 centímetros de la pared donde están montados los sensores ($d=30$) y separadas 10 centímetros una de otra ($l=10$).

Para simular las señales emitidas por las DP, se escogieron de manera aleatoria las señales desde el conjunto de 25 de cada tipo. La cantidad de señales por cada tipo en cada simulación fue desde 5 a 20 señales. Ejemplo: En la simulación mostrada en la Figura 4.7 se escogieron 7 señales para DP interna (grafica (a)) y 10 para DP superficiales (grafica (b)) de manera aleatoria y después se colocaron secuencialmente en diferentes posiciones temporales, también de manera aleatoria. Los pulsos de descarga están esparcidos a lo largo de $3000 \mu s$. Se asume una velocidad de muestreo de 1 MHz. Para la DP interna s_1 hay siete pulsos colocados en las siguientes posiciones temporales: $250 \mu s$, $655 \mu s$, $768 \mu s$, $806 \mu s$, $900 \mu s$, $1208 \mu s$, $1611 \mu s$. Para la señal acústica de DP superficial s_2 , en las siguientes posiciones: $119 \mu s$, $420 \mu s$, $458 \mu s$, $600 \mu s$, $742 \mu s$, $896 \mu s$, $1037 \mu s$, $1290 \mu s$, $1488 \mu s$, $1716 \mu s$, lo suma un total de diez pulsos. Los intervalos entre cada pulso van desde $50 \mu s$ a $500 \mu s$. Con esto se logró simular la actividad de DP desde cada tipo de fuentes s_1 y s_2 de tal forma que el algoritmo ICA-Amari fue probado con diferentes mezclas y niveles de solapamiento entre las señales.




Figura 4.7. Amplitud en Unidades Arbitrarias (U. A.). a) Señal acústica original desde la fuente DP interna s_1 , b) Señal acústica original desde la fuente DP superficial s_2 .

Para simular el mezclado en los sensores x_1 y x_2 se utilizó la ecuación (3.5):

$$x_i(t) = \sum_{j=1}^N \sum_{k=0}^{L-1} a_{ijk} s_j(t-k)$$

Con $N = 2$, $i, j = 1, 2$ debido ya que hay dos fuentes y dos sensores, respectivamente. Para el cálculo de la longitud L de los filtros se realiza el siguiente análisis. En la Figura 4.6 las dos fuentes s_1 y s_2 tiene igual distancias (30 centímetros) a los sensores x_1 y x_2 , respectivamente, por lo que sus emisiones deben llegar al mismo tiempo. El momento de llegada de cada frente de onda a cada sensor es tomado como el inicio de la señal. Las emisiones cruzadas, es decir, $s_1 - x_2$ y $s_2 - x_1$ tienen el mismo retardo con respecto a los frentes de onda directas, en esta simulación. Como se ha explicado en la sección 3.4 este retardo es el TDOA entre los sensores y es el mismo para las dos fuentes debido a la geometría del esquema.

El TDOA es calculado obteniendo primero el retardo entre la fuente s_1 y el sensor x_1 de la siguiente manera:

$$\tau_1 = d/v = 30\text{cm}/0.142 \text{ cm}/\mu\text{s} = 211.3 \mu\text{s}.$$

Después es obtenido el tiempo $s_1 - x_2$:

$$\tau_2 = d/v = 31.6\text{cm}/0.142 \text{ cm}/\mu\text{s} = 222.7 \mu\text{s}.$$

Donde d es la distancia entre la fuente y el sensor correspondiente en centímetros y v es la velocidad de la onda. En estos cálculos se ha asumido una velocidad de $v=0.1420$

cm/ μ s igual a la velocidad del sonido en el aceite mineral usado en los transformadores. El TDOA, τ_{12} , es la diferencia $\tau_1 - \tau_2 = 11.4 \mu$ s. Es importante resaltar que la velocidad asumida no afecta el desempeño del algoritmo ICA-Amari. Se pudo haber escogido cualquier otra velocidad y lo único que cambia la posición de los TDOA.

La longitud del filtro L se obtiene utilizando el mayor retardo que pueda sufrir la onda en su propagación desde la fuente hasta el sensor. Este tiempo puede ser el tomado por el frente de onda directo o por las reflexiones. En estas simulaciones no son consideradas las reflexiones por lo que es igual al retardo de las señales cruzadas $s_1 - x_2$ y $s_2 - x_1$ y es calculado utilizando la ecuación:

$$L = \tau_m f_s \quad (4.1)$$

Donde τ_m es el máximo retardo y f_s es la frecuencia de muestreo. Asumiendo una velocidad de muestreo de 1 MHz esto resulta en 11.4 muestras que puede ser redondeado a 11. Con estos cálculos la longitud es $L = 11$. Es importante resaltar que el redondeo causa un problema de resolución ya que 0.4 muestras equivalen a 0.4μ s y a 0.05 cm de distancia. Esta situación produce un error que este caso es bajo, pero que puede ser importante en señales más rápidas como las electromagnéticas que viajan a la velocidad de la luz. Cuando se trabaja con el método de detección electromagnética es necesario utilizar tasas de muestreo superiores a 1 GHz, por lo que una muestra representa 30 centímetros y en caso de 0.4 el error equivale a 12 centímetros.

En la Figura 4.8 se muestran los cuatro filtros utilizados para crear las mezclas con la ecuación (3.6). Los filtros a_{11} y a_{22} simula el momento de llegada del frente de onda de las fuentes s_1 y s_2 a los sensores x_1 y x_2 , respectivamente. Este momento es representado por un valor unitario en la muestra cero y son iguales para los dos sensores, ya que están a las mismas distancias de las fuentes. Los filtros a_{12} y a_{21} simulan el retardo de la señal desde la fuente hasta el sensor más lejano, $s_1 - x_2$ y $s_2 - x_1$, respectivamente. Este retardo, igual a 11 muestras es igual para los dos casos. En los filtros la amplitud de cada parámetro representa la intensidad de la señal. En los dos filtros a_{11} y a_{22} la muestra cero tiene un valor unitario, lo que indica que la señal tiene el máximo valor con respecto a esta misma señal llegando a otros sensores más alejados. Esto representa la atenuación debido a la distancia. Para los filtros a_{12} y a_{21} el valor de la muestra diez es la mitad de la muestra cero. Como se mencionó anteriormente, se toma como referencia inicial la

llegada de la señal a los sensores más próximos a la fuente. Toda señal que llegue después será de menor valor debido a que recorre una mayor distancia.




Figura 4.8. Filtros utilizados para crear las mezclas. Todos tienen una longitud $L = 11$.

En todas las simulaciones se realizan las siguientes consideraciones: 1) se toma como punto de inicio temporal el punto de llegada al sensor más próximo como se ha explicado anteriormente; 2) para simplificar la simulación no son considerados los rebotes, sólo el mezclado con retardo; 3) el medio de propagación es considerado homogéneo por lo que hay atenuación debido sólo a la distancia. No se considera la dispersión ni el cambio en la velocidad de la onda debido a su frecuencia.

En la gráfica (a) y (b) de Figura 4.9 se muestra la señal acústica en el sensor x_1 y sensor x_2 , respectivamente. En ninguna de las dos graficas es posible contar siete o diez pulsos contenidos en las señales originales s_1 o s_2 , respectivamente.




Figura 4.9. Amplitud en Unidades Arbitrarias (U. A.). a) Señal acústica medida en el sensor x_1 , b) Señal acústica medida en el sensor x_2 .

La superposición no sólo cambia la forma de onda de las fuentes sino de otras características como la huella de energía obtenida desde la descomposición Wavelet. En la Figura 4.11, graficas (a) y (b) se muestra las huellas Wavelet de las mezclas x_1 y x_2 , respectivamente, de la simulación de ejemplo mostradas en la Figura 4.7. Estas huellas defieren de los valores de las fuentes originales como se muestran en la Figura 4.5. Utilizando el coeficiente de correlación Pearson se pueden comparar cuantitativamente. Ejemplo: la huella de energía de la fuente s_1 con la señal del sensor x_1 tiene una correlacion de 0.55 y la huella de la fuente s_2 con el sensor x_1 de 0.82. Son valores muy bajos para establecer una identificación. Las señales en los sensores han cambiado su forma de onda y espectro con respecto a las originales, características necesarias para el desempeño de los métodos de identificación tradicionales expuestos en capítulo 2.

Las mezclas sintéticas son procesadas por el algoritmo ICA-Amari. En la Figura 4.10 se muestran el resultado: las señales y_1 y y_2 . En esta prueba es utilizado el algoritmo ICA-Amari descrito en la Tabla 3.5 y un bloque de muestras de tamaño 2×2000 que contienen las señales mostradas en las gráficas (c) y (d) de la Figura 4.7. Estos resultados son alcanzados con los valores de los parámetros mostrados en la Tabla 4.2 los cuales serán explicados con más detalles en la sección 4.5. Es posible contar los pulsos y calcular su posición temporal guiándonos por las amplitudes máximas. Las posiciones son: $250 \mu s$, $655 \mu s$, $768 \mu s$, $806 \mu s$, $900 \mu s$, $1208 \mu s$, $1611 \mu s$ que suman un total de siete pulsos igual cantidad a la señal original s_1 . Si lo comparamos con las posiciones temporales de las señales originales son las mismas. Esto ocurre de igual manera para la señal y_2

comparandola con s_2 : 119 μs , 420 μs , 458 μs , 600 μs , 742 μs , 896 μs , 1037 μs , 1290 μs , 1488 μs , 1716 μs ; que suman diez pulsos.




Figura 4.10. Estimaciones resultantes del algoritmo ICA-Amari. (a) Estimación y_1 y (b) estimación y_2 .

Tabla 4.2. Valores para los parámetros del algoritmo ICA-Amari para mezclas convolutivas

Función de activación	$sign()$
Longitud del filtro	$L = 25$
Tasa de aprendizaje	$\eta = 10^{-2}$
Valores iniciales de \mathbf{W}_0	Ceros en la diagonal y unos fuera de la diagonal
Valores iniciales de $\mathbf{W}_k, k = 1, 2, \dots, L$	Ceros en todos los elementos
Numero de iteraciones	$it = 20$
Condición de parada	$\delta = 10^{-3}$

Para tener criterio cuantitativo de la calidad de la separación se ha calculado la huella de energía Wavelet de las estimaciones y_1 y y_2 la cuales son mostradas en las Figura 4.11 d) y Figura 4.11 d), respectivamente. En la Tabla 4.3 se comparan las huellas Wavelet de las fuentes s_1 y s_2 con las huellas Wavelet de las estimaciones y_1 y y_2 . En este caso los valores de correlación indican que la estimación y_1 tiene una correlación de 0.98 con la fuente de DP interna s_1 y la estimación y_2 un valor de correlación de 0.99 con la fuente de DP superficial s_2 . De este analisis se puede concluir que el algoritmo ha logrado recuperar la forma de onda de las señales originales y con la comparativa de la huella

Wavelet se ha posibilitado la identificación de los dos tipos de fuentes: interna y superficial.

Tabla 4.3. Comparación entre las huellas Wavelet de las fuentes y las estimaciones.

Huella de las señales a comparar	Coefficiente de correlación Pearson
Fuente s_1 vs y_1	0.98
Fuente s_2 vs y_2	0.99
Fuente s_1 vs y_2	0.64
Fuente s_2 vs y_1	0.55

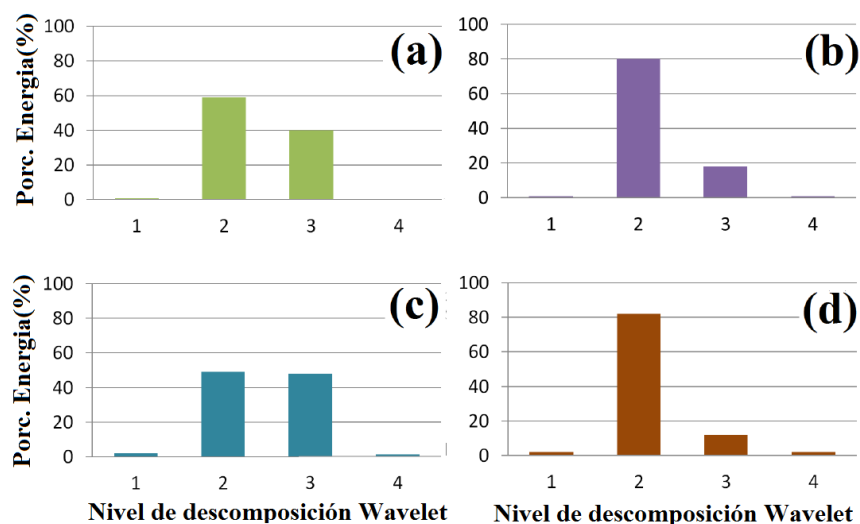


Figura 4.11. Huella de energía para las señales usadas en la simulación. a) señal en el sensor x_1 , b) señal en el sensor x_2 , c) señal estimada y_1 (DP interna), y d) señal estimada y_2 (DP superficial).

4.4. Identificación utilizando mezclas acústicas reales

Para la evaluación del algoritmo ICA-Amari con mezclas acústicas reales, la activación y localización de cada fuente debe ser controlada como fue realizado en las simulaciones de la sección anterior. Debido a la aleatoriedad del proceso de generación de DP en un ambiente real, este control no es posible. Por esta razón, se realizó un experimento controlado en el cual se generan pulsos acústicos similares a los ocasionados por las descargas reales.

El esquema del montaje para el experimento se muestra en la Figura 4.12. Consiste en un tanque lleno de agua de dimensiones 103 cm x 63 cm x 63 cm, unas paredes de PMMA de 1.4 cm de espesor y con paneles anecóicos como se muestran en la Figura 4.13. Para la medida de las señales son utilizados dos sensores de emisiones acústicas marca Physical Acoustic Corporation, modelo R15i-AST. Estos se encuentran fijados a

la pared externa del tanque como se muestra en la Figura 4.13. Estos sensores son usados en aplicaciones típicas para la detección de DP en transformadores de potencia como ha sido mencionado en el capítulo 2. Para la adquisición de las señales fue utilizado un sistema multicanal marca National Instruments, modelo PXI 5105 como se muestra en la Figura 4.14.




Figura 4.12. Esquema descriptivo del montaje del experimento. Los transductores ultrasónicos s_1 y s_2 y los sensores acústicos x_1 y x_2 están en el mismo plano horizontal; las medidas todas son en centímetros. Las coordenadas mostradas son un ejemplo y pueden ser cambiadas dependiendo de la necesidad.

Una fuente de DP actúa como una fuente fija de emisiones acústicas liberando energía mecánica en forma de pulsos cortos. Para generar estos pulsos fue utilizado un generador de funciones arbitrarias marca RIGOL, modelo DG4162 el cual es mostrado en la Figura 4.15. Este equipo tiene dos canales que son utilizados para enviar pulsos eléctricos y excitar dos transductores ultrasónicos funcionando en modo emisor. Estos transductores son marca y modelo Brüel & Kjær 8103, especiales para aplicaciones bajo el agua; con un rango de operación de 100kHz a 300kHz, sensibilidad de 137dB relativa a 1 μ PA/Volt a 1 metro y con una emisión omnidireccional. En la Figura 4.13 se muestra el tanque con agua y dentro los transductores para la simulación de las descargas. Cada uno está fijados a una regla metálica y en la parte superior de esta regla a un cuadro de metal, el cual permite mover los dos transductores a diferentes posiciones. Pueden ser acercados o alejados entre ellos. También es posible acercarlos o alejarlos a los sensores de EA. Es

importante mencionar que el banco de ensayo permite colocar tanto los transductores y sensores en posiciones fijas en un sistema de coordenadas de tres dimensiones.

Los transductores conectados por medio de un cable coaxial al generador de pulsos RIGOL. El arreglo generador/transductor permite generar pulsos acústicos con diferente ancho y amplitud. Además, puede ser controlado el intervalo temporal entre dos consecutivos pulsos. Esto permite realizar mezclas de manera similar a las mezclas sintéticas del apartado anterior y comparar los resultados.




Figura 4.13. Vista real de tanque, y las posiciones de los sensores de emisiones acústicas fijados a la pared externa del tanque y los transductores ultrasónicos.

En el experimento fue utilizado como medio de propagación el agua, en el cual las ondas acústicas tienen una velocidad de 1490 m/s muy cercana a la velocidad de estas ondas en el aceite de transformador la cual es de 1420 m/s. Es importante destacar que, a pesar de la diferencia de los medios, estos son homogéneos lo que permite asumir linealidad en el comportamiento de las señales. Para el trabajo del algoritmo son condiciones suficientes por lo que las diferencias no afectan su desempeño y los resultados son similares para los dos tipos de medios.




Figura 4.14. Sistema de adquisición multicanal marca National Instruments, modelo PXI 5105. En su pantalla se muestran la forma de onda de los pulsos enviados a los transductores ultrasónicos y las señales acústicas medidas por los sensores de emisiones acústicas.

El montaje descrito permite controlar la posición, forma de onda, espectro, amplitud, tiempo de disparo e intervalo entre pulsos. En el montaje del experimento (ver Figura 4.12) el transductor s_1 , emite ondas acústicas similares a una fuente de DP interna y el transductor, s_2 a una fuente DP superficial. En la figura se muestra que las fuentes están a 22 cm de distancia una de la otra y cada una frente a los sensores, x_1 y x_2 , respectivamente. Las fuentes están a una distancia de 30 cm de la pared del tanque donde están colocado los sensores. Estas distancias son extraídas de una de las simulaciones realizadas en el banco de ensayo. Se realizaron múltiples simulaciones con las fuentes y sensores en diferentes posiciones.




Figura 4.15. Generador de funciones arbitrarias marca RIGOL, modelo DG4162. Sus dos canales son conectados a cada transductor ultrasónico. En la pantalla se muestran los pulsos eléctricos enviados para excitar estos transductores.

4.4.1. Generación de señales acústicas reales

En el mezclado sintético se utilizaron como fuentes, señales desde un conjunto de 25 señales reales de DP. El banco de ensayos permite crear señales acústicas similares a estas señales. De cada señal del conjunto de las 25 señales de DP internas y superficiales se obtienen sus características: contenido espectral, ancho del pulso, amplitud, tiempo de subida y bajada. Posteriormente, se utiliza el banco de ensayos para generar una señal similar. Para facilitar el análisis se diseñó un programa en LABVIEW el cual muestra las características de las señales reales y las compara con las características de la señal medida en los sensores. Esto se realiza enviando pulsos a uno de los transductores. Estos pulsos tienen una amplitud, ancho, subida y bajada modulable, los cuales son medidos por uno de los sensores de EA. A la señal medida se le extraen sus características de onda y se le compara con las características de la señal real. El pulso es modificado hasta que sea similar al pulso de las DP reales. Los valores fijados en el RIGOL para crear el pulso son identificado y guardados. Esta operación se realizó para crear una base de datos con señales acústicas similares a los 25 reales de referencia, tanto para DP internas como superficiales.

Para evaluar la similitud de estas señales con las reales se obtuvo su huella wavelet y se comparó con la huella de las reales. Los resultados son presentados en la Figura 4.16 donde se muestran las huellas de las señales medidas en cada tipo. Desde el transductor s_1 se genera una señal acústica simulando una fuente DP interna. El sensor x_1 mide esta señal y en la Figura 4.16 (a) se presenta su huella Wavelet. Haciendo un análisis de

correlación de esta huella con la huella de las señales reales de DP interna se obtuvo un valor de 0.99. Esta operación se realiza de igual forma con el transductor s_2 pero generando una señal similar a una fuente real de una DP superficial. En este caso el transductor s_1 no recibe señal para evitar interferencia. Con el sensor x_2 se mide esta señal y se obtiene su huella Wavelet. En este caso arrojo un resultado de correlación de 0.99 con la huella de la señal real. Esta huella se muestra en la Figura 4.16 (b). De esta forma, utilizando este montaje obtenemos señales acústicas similares a las obtenidas en un laboratorio de alta tensión para generación de DP reales.




Figura 4.16. (a) Huella generada por la señal emitida desde el transductor s_1 la cual es similar a la fuente de DP interna. (b) Huella generada por la señal emitida desde el transductor s_2 la cual es similar a la fuente de DP superficial.

4.4.2. Generación de las mezclas

Para la generación de las mezclas con señales acústicas reales se crean pulsos con el generador de funciones RIGOL de tal manera que simulen las DP en los transductores s_1 y s_2 , los cuales serán la fuente de DP interna y superficial, respectivamente. En la Figura 4.17, graficas (a) y (b) se muestran un ejemplo representativo de las mezclas obtenidas en los sensores x_1 y x_2 , respectivamente. Para obtener estas señales, el canal 1 del generador de onda arbitrario conectado al transductor s_1 fue programado para generar cuatro pulsos en las siguientes posiciones temporales: $0 \mu s$, $504 \mu s$, $905 \mu s$ y $1305 \mu s$ desde el disparo de inicio. El canal 2 conectado al transductor s_1 generó los pulsos en las siguientes posiciones temporales: $0 \mu s$, $280 \mu s$, $500 \mu s$, $630 \mu s$, $800 \mu s$, $1050 \mu s$ y $1200 \mu s$ desde el disparo de inicio. El tiempo entre dos pulsos consecutivos fue programado con valores desde $25 \mu s$ a $50 \mu s$ con el objetivo de lograr que las señales fuentes acústicas sufrieran interferencia mutua al arribar a los sensores. La adquisición de las señales es sincronizada el inicio del primer pulso del canal 1. El tiempo de adquisición fue

establecido en $1800 \mu s$ tiempo suficiente para obtener las mezclas de todos los pulsos enviados. Se utilizó una frecuencia de muestreo de 1 MS/s por lo que el tamaño del bloque grabado es de 1800 muestras. El índice de evaluación empleado fue el mismo que para las simulaciones del capítulo 4: el coeficiente de correlación Pearson entre el patrón Wavelet de las estimaciones desde el algoritmo ICA-Amari y el patrón de las fuentes originales.

4.4.3. Separación de mezclas utilizando el algoritmo ICA-Amari

Las señales obtenidas de los sensores x_1 y x_2 fueron procesadas por el algoritmo ICA-Amari. El trabajo de separación puede ser observado en las gráficas (c) y (d) de la Figura 4.17, donde se muestran las señales estimadas y_1 y y_2 , respectivamente. En la señal y_1 es posible observar los cuatro pulsos acústicos originalmente emitidos por el transductor s_1 . Por otro lado, en y_2 los siete pulsos desde s_2 . De esta manera, el algoritmo ICA-Amari ha separado y estimado las señales originales, y_1 , como una señal acústica desde DP tipo interna y en, y_2 , una señal acústica desde DP tipo superficial.

Los parámetros para la operación del algoritmo ICA-Amari: longitud de los filtros y tasa de aprendizaje fueron escogidos de la siguiente manera. Para la longitud de los filtros L se utilizó como referencia el máximo retardo entre dos pulsos consecutivos, el cual era de $50 \mu s$. Para obtener la longitud en muestras se utilizó la ecuación (4.4.9): $L = \tau_m f_s$, donde $\tau_m = 50 \mu s$ y $f_s = 1 \text{ MS/s}$, resultando en $L = 50$. La longitud L inicialmente fue establecida en 25 y se fue cambiando en pasos de tamaño 5 hasta 200. A pesar de que el retardo era de $50 \mu s$ para una $L = 50$, no se obtuvieron los mejores resultados de correlación con esa longitud. La longitud $L = 100$ produjo el mejor valor de correlación igual a 0.98. Un mayor valor para la longitud no resultó en ninguna mejora. En estas pruebas se utilizó una tasa $\eta = 0.01$. Una tasa con un valor mayor producía inestabilidad y una tasa menor resultaba en una mayor cantidad de iteraciones. Los valores óptimos después de realizar varias pruebas son los mostrados en la Tabla 4.4.

Tabla 4.4. Parámetros para el algoritmo ICA-Amari para separación de dos fuentes.

Parámetro	Valor con mezclas reales
Longitud del filtro	$L = 100$
Tasa de aprendizaje	$\eta = 0.01$

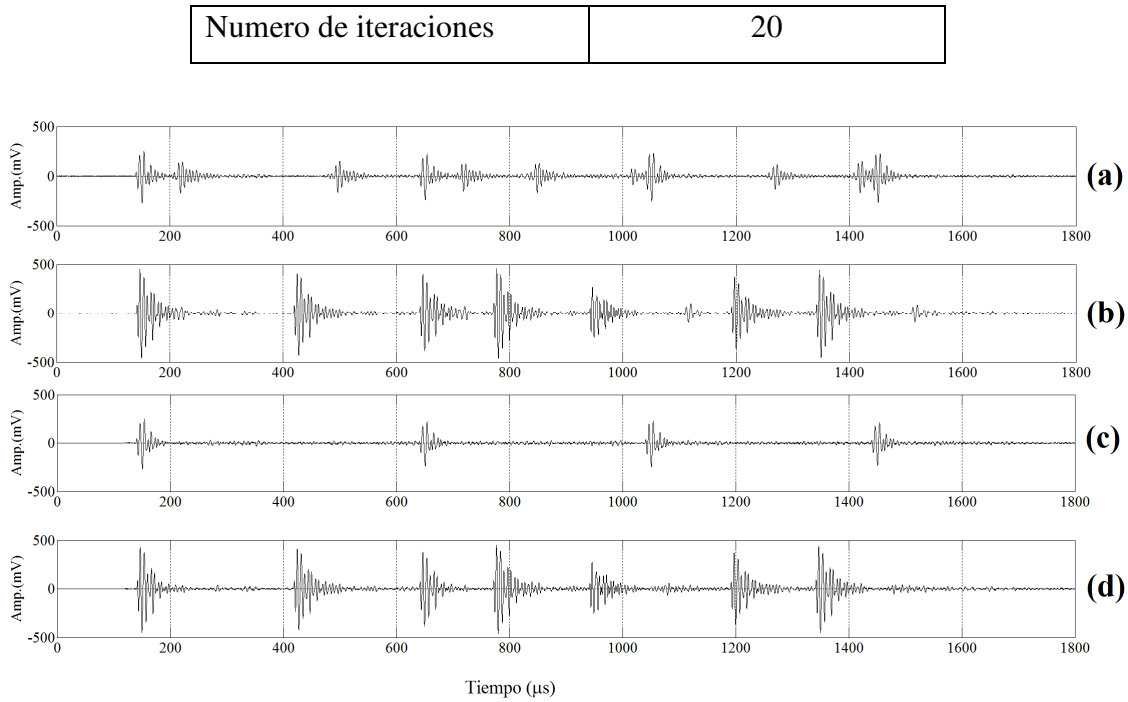


Figura 4.17. (a) Señal acústica en el sensor x_1 , (b) señal acústica en el sensor x_2 , (c) y (d) señales estimadas y_1 y y_2 por el algoritmo ICA-Amari, respectivamente.

En la Figura 4.18 se muestran la huella o patrón Wavelet para las señales mezclas obtenidas en los sensores y las señales estimadas por el algoritmo ICA-Amari. Es posible observar desde las mezclas que el proceso de mezclado cambió el patrón Wavelet con respecto al patrón original mostrado en la Figura 4.16, lo que dificulta la identificación de los tipos de fuentes de DP generados en el experimento. Sin embargo, el algoritmo recuperó las características temporales y de frecuencia de las fuentes s_1 y s_2 . Esto permite una identificación de cada tipo de DP interna y superficial por medio la técnica de extracción con la transformada Wavelet y el coeficiente de correlación. Además de la identificación, la recuperación de las características temporales permite la localización de las fuentes utilizando métodos de estimación de TDOA.

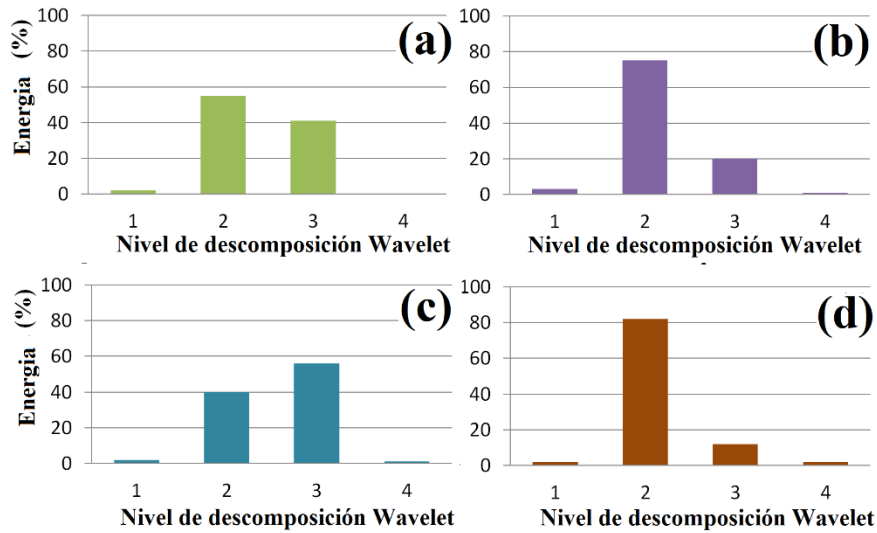


Figura 4.18. Huella de energía para señales reales acústicas. (a) Mezcla real desde el sensor x_1 . (b) Mezcla real desde el sensor x_2 . (c) Señal estimada y_1 . (d) Señal estimada y_2 .

4.5. Análisis de parámetros del algoritmo ICA-Amari

4.5.1. La función de activación

El primer parámetro que discutir es la función de activación $\varphi()$. Este parámetro depende de la distribución de densidad de probabilidad de las fuentes. En la Figura 4.19 se muestra el histograma para el conjunto de las 25 señales por cada tipo. Estas distribuciones tienen una forma aproximada a la función de distribución de probabilidad laplaciana (ver Figura 4.20) que tiene como función de activación correspondiente $\text{sign}(u)/\sigma$, donde u es la variable y σ es la desviación estándar la cual es unitaria ya que las señales están normalizadas. Esta función de activación fue la escogida para todas las pruebas con mezclas simuladas y reales.




Figura 4.19. Distribuciones de las señales fuentes. Se han utilizado las 25 señales por cada tipo para generarlas. (a) Interna, (b) Superficial.

En la Figura 4.20 se muestra la forma de la distribución laplaciana y su función de activación. Esta función de activación es escogida para el algoritmo ICA-Amari si las fuentes presentan este tipo de función de densidad de probabilidad.

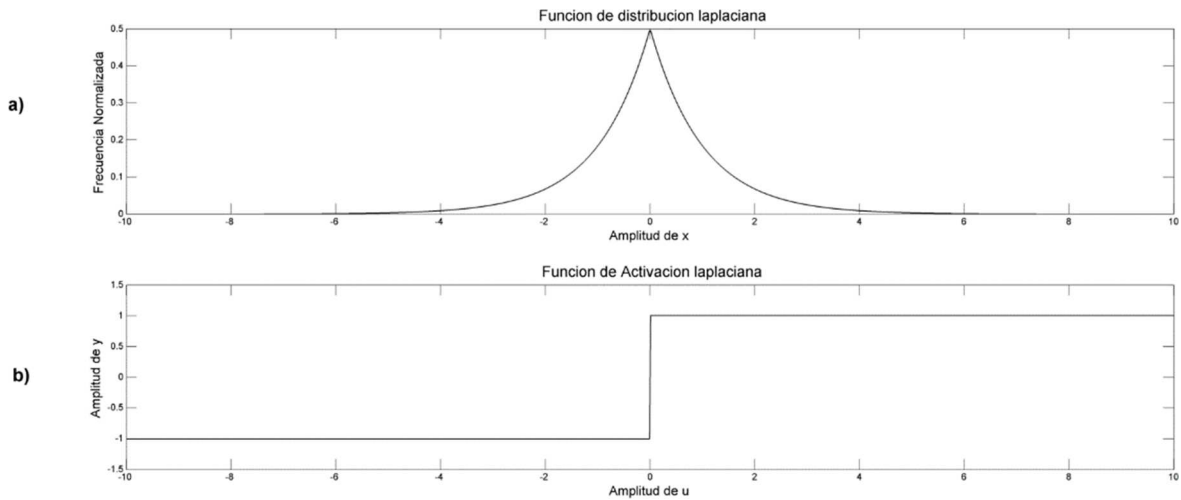


Figura 4.20. a) Función de distribución laplaciana. b) Función de activación derivada de la función de distribución laplaciana. Como se puede observar es una función $\text{sign}()$ en donde para cualquier valor u mayor de cero resulta en +1 y para valores negativos de u , en -1.

4.5.2. La longitud de los filtros, tasa de aprendizaje e iteraciones

El siguiente parámetro que analizar es la longitud de filtro L el cual depende del máximo retardo de las señales. En las pruebas fueron utilizadas inicialmente la misma longitud de los filtros de mezclado, sin embargo, con el objetivo de generalización se probaron otros valores de longitud. Con mezclas reales no es posible conocer a priori las longitudes de los filtros de mezclado. Este es uno de los parámetros desconocidos y es necesario evaluar el efecto de utilizar longitudes diferentes. En la Figura 4.21 se muestra el efecto de la longitud de los filtros con respecto a la calidad de la separación. Se utiliza el coeficiente de correlación para evaluar el rendimiento y se compara para tres distintas tasas de aprendizaje. En esta gráfica se compara la huella de energía de la estimación y_1 con la huella de energía de la fuente de DP interna s_1 . Se utilizaron longitudes desde $6 \leq L \leq 26$ en pasos de 2. En todas estas pruebas se utilizaron 30 iteraciones para lograr estos resultados.

Para $\eta = 0.1$ la calidad en la separación tiene el mayor valor de correlación, 0.99, sin embargo, si se sigue aumentando la longitud, la operación del algoritmo se torna inestable. Se ha colocado valores de cero desde la longitud 20 para mostrar este problema.

Con $\eta = 0.01$ el valor de correlación fue de 0.98 y se mantuvo estable para todas las longitudes. Igualmente sucedió con $\eta = 0.001$ sin embargo, en este caso dio el menor valor de correlación que con las otras tasas de aprendizaje, 0.91. Resultados similares fueron obtenidos cuando se analizó el rendimiento para la estimación y_2 .

De este análisis se puede concluir que un valor inferior a la longitud de mezclado producirá un bajo rendimiento y que debe aumentarse la longitud de tal forma que sea más grande que el retardo de las señales. Por otro lado, a medida que se aumenta la tasa de aprendizaje hay mayor correlación entre las estimaciones y las señales fuentes sin embargo hay riesgo de inestabilidad. Para verificar esto se aumentó a una tasa de $\eta = 0.5$. El algoritmo ICA-Amari fue inestable en toda la operación y para cualquier longitud. Esta inestabilidad se presentaba como una oscilación que crecía hasta valores muy grandes en las estimaciones.

En la Figura 4.22 se muestra el efecto del número de iteraciones sobre el coeficiente de correlación entre la huella de energía de la estimación y_1 y la huella de energía de la fuente interna s_1 para diferentes tasas de aprendizaje. Para este análisis fue utilizado una $L = 14$. Con la tasa más alta, $\eta = 0.1$, se logra el mejor valor de correlación 0.99 con la menor cantidad de iteraciones. A medida que se disminuye la tasa, es necesario más iteraciones para conseguir un buen valor de correlación.

De este análisis se puede concluir que hay que tener un compromiso entre el rendimiento y la cantidad de iteraciones lo cual se traduce en tiempo de procesamiento. Si se utiliza una tasa de aprendizaje alta hay riesgo de inestabilidad, pero el algoritmo ICA-Amari converge en menos iteraciones. Esto es un importante factor ya que, en mezclas reales, no se conoce a priori el retardo, el cual puede ser muy largo en muestras. Si se empieza por una longitud muy alta para resolver este problema y es utilizada una tasa muy baja para evitar inestabilidad, el algoritmo ICA-Amari puede tomar demasiadas iteraciones para alcanzar una buena separación o incluso nunca alcanzarla. Para evaluar este problema se utilizó una $L = 500$ para crear las mezclas, lo que simula un retardo de $500 \mu s$ equivalente a 71 centímetros. El algoritmo necesitó 1500 iteraciones para llegar a un coeficiente de 0.95 con una tasa de 0.001. Tasas de más alto valor hacían inestable la operación. Es importante resaltar que el retardo considerado es con respecto al momento de llegada del frente de onda a los sensores y que no contempla el tiempo gastado por la señal desde la fuente a los sensores el cual es mucho mayor y por consiguiente una mayor distancia.

Del análisis de las Figura 4.22, también se puede concluir que cuando la tasa de aprendizaje es correcta y se llega a un valor óptimo de separación, el algoritmo continúa operando hasta una cantidad fija de iteraciones it haciendo perder tiempo en la operación. Para evitar esto, se fija una condicion de parada δ . En la Tabla 4.5 se muestran tres valores para δ , el numero de iteraciones utilizadas it y el respectivo coeficiente de correlación para este número de iteraciones. Con un valor de δ alto es necesario menos iteraciones sin embargo el algoritmo no llega a su valor óptimo de separación, por otro lado, con un valor muy bajo el algoritmo sigue operando a pesar de que ya ha alcanzado valores estables en los pesos de separación. Los valores de los parámetros mostrados en la Tabla 4.2 fueron los que mejor rendimiento ofrecieron para todas las pruebas por lo que fueron utilizados en las pruebas con mezclas reales.




Figura 4.21. Efecto de la longitud de los filtros con respecto a la calidad de la separación. Se utiliza el coeficiente de correlación para evaluar el rendimiento y se compara para tres distintas tasas de aprendizaje. En esta grafica se compara la huella de energía de la estimación y_1 con la huella de energía de la fuente de DP interna s_1 .




Figura 4.22. Relación entre el número de iteraciones y el coeficiente de correlación para diferentes tasas de aprendizaje. En esta gráfica se compara la huella de energía de la estimación y_1 con la huella de energía de la fuente de DP interna s_1 .

Tabla 4.5. Condición de parada δ del algoritmo ICA-Amari, el número de iteraciones utilizadas y el coeficiente de correlación para esa cantidad de iteraciones. En este análisis se la compara la huella de energía de la estimación y_1 con la huella de energía de la fuente de DP interna s_1 .

Condición de parada δ	Numero de iteraciones	Coeficiente de correlación
0.1	5	0.81
0.01	13	0.90
0.001	22	0.98
0.0001	30	0.98

4.6. Localización de múltiples fuentes de DP

En esta sección se presenta un método para la estimación de TDAO en un ambiente donde existen más de una fuente de DP utilizando el método de detección acústica. Es basado en el trabajo presentado en (Boya et al., 2015b) por el autor de esta tesis. En ese trabajo se propone la estimación de TDOA para localización de una fuente de DP con el método de detección electromagnético y el algoritmo ICA-Amari. El método utiliza información desde los pesos estimados por el algoritmo. En esta tesis el trabajo en (Boya et al., 2015b) es extendido para estimar TDOA cuando existen más de una fuente de DP.

Para la estimación de los TDAO se utilizan los pesos contenidos en la matriz \mathbf{W}_k estimada por el algoritmo ICA-Amari:

$$\mathbf{W}_k = \begin{bmatrix} 0 & w_{12k} \\ w_{21k} & 0 \end{bmatrix}, \text{ para } k = 1, 2, \dots, L-1;$$

Los pesos \mathbf{W}_k son los filtros de convolución usados por el algoritmo para realizar la separación de las mezclas de las fuentes y tienen la siguiente forma vectorial: $\mathbf{w}_{12} = [w_{120}, w_{121}, \dots, w_{12L-1}]$ y $\mathbf{w}_{21} = [w_{210}, w_{211}, \dots, w_{21L-1}]$. Como se explicó en la sección 3.4.1 los pesos \mathbf{w}_{ij} están relacionados a los coeficientes de mezclado \mathbf{a}_{ij} cuando hay dos mezclas: $\mathbf{w}_{12} = -\mathbf{a}_{21}$ y $\mathbf{w}_{21} = -\mathbf{a}_{12}$, donde \mathbf{a}_{12} y \mathbf{a}_{21} ; de tal manera que los pesos contienen información relativa a los TDOA de las fuentes, s_1 y s_2 . Para encontrar los TDOA se busca el índice del parámetro con el máximo valor de amplitud de cada peso. Con este procedimiento \mathbf{w}_{21} contiene el TDOA de la fuente s_1 y \mathbf{w}_{12} el TDOA de la fuente s_2 .

Para evaluar este método se utiliza el montaje de generación de fuentes acústicas de DP simuladas de la Figura 4.12. Las fuentes s_1 y s_2 son colocadas en tres distintas posiciones como se muestra en Tabla 4.6. En este experimento se agrega un sensor adicional para evaluar el método en una localización de dos dimensiones. Las posiciones de los sensores son presentadas en la Tabla 4.6 y en la Figura 4.23 se muestra el montaje indicando los tres sensores con el sensor x_1 en el origen de las coordenadas.

Tabla 4.6. Posiciones de las fuentes (s_1 y s_2) y los sensores (x_1 , x_2 y x_3)

Posición	Elemento	Coordenada (centímetros)	
		x	y
1	S1	-10	15
	S2	35	15
2	S1	-20	30
	S2	45	30
3	S1	-25	10
	S2	40	25
1, 2, 3	X1	0	0
	X2	15	0
	X3	30	0

En estas pruebas se utilizaron los valores de los parámetros del algoritmo mostrados en la Tabla 4.4. En la primera prueba se activa sólo una fuente a la vez. En la Figura 4.24

se muestran los coeficientes de los filtros w_{12} y w_{21} estimados por el algoritmo con la fuente s_1 activa en la posición 1 de la Tabla 4.6. El TDOA es obtenido del filtro w_{21} ya que tiene un máximo en la muestra 5 (se debe restar una unidad para obtener la muestra correcta), lo que es equivalente a un retardo de $0.5 \mu s$. Cuando hay una sola fuente uno de los filtros tiene máximos apreciables con respecto al otro. La observación de estos máximos es una forma indirecta de determinar la presencia de más de una fuente. En muchas pruebas realizadas, se determinó que cuando sólo había una fuente activa, la diferencia promedio porcentual entre la mayor amplitud entre los dos pesos, era de 90%. Cuando se activaban las dos fuentes se podían observar máximos apreciables en los dos pesos llegando incluso a tener similares amplitudes, lo que depende de la posición espacial de las fuentes.

En la Figura 4.25 se muestran los filtros w_{12} y w_{21} utilizando las señales obtenidas en los sensores x_1 y x_3 con solo la fuente s_1 activa en la misma posición 1. En este caso el TDOA también es obtenido del filtro w_{21} que tiene un máximo en la muestra 23 equivalente a un retardo de $2.3 \mu s$.

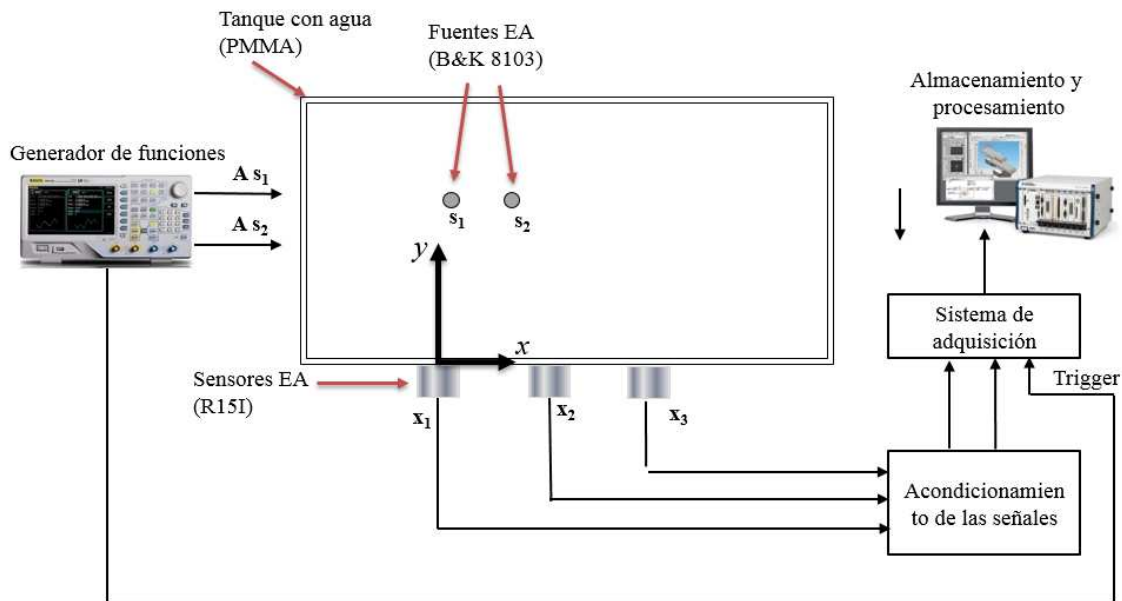


Figura 4.23. Montaje experimental para generar mezclas desde múltiples fuentes de DP (vista de planta).




Figura 4.24. Filtros para la estimación de los TDOA entre los sensores x_1 y x_2 cuando solo está activa una fuente. En este caso la fuente de DP Interna s_1 . U.A: Unidades arbitrarias.

Utilizando el proceso explicado anteriormente se obtienen los TDOA para todas las posiciones de las fuentes s_1 y s_2 mostradas en la Tabla 4.6. En la siguiente prueba se activan las dos fuentes s_1 y s_2 . En la Fig. 8 se muestran como resultado los filtros w_{12} y w_{21} estimados por el algoritmo ICA para los sensores x_1 y x_2 . En este caso los dos filtros presentan máximos por encima del valor de umbral establecido. Del filtro w_{21} se obtiene $\tau_{21} = 8$ muestras o $0.8 \mu s$ que es el TDOA de la fuente s_2 utilizando como referencia x_2 con respecto al sensor x_1 ; y del filtro w_{12} se obtiene $\tau_{12} = 5$ muestras o $0.5 \mu s$, TDOA para la fuente s_1 utilizando como referencia x_1 con respecto a x_2 . Para obtener el siguiente par de TDOA se utilizan las señales de los sensores x_1 y x_3 y se realiza la misma operación.




Figura 4.25. Filtros para la estimación de los TDOA entre los sensores x_1 y x_3 cuando solo está activa una fuente. En este caso la fuente de DP Interna s_1 . U.A: Unidades arbitrarias.

Para evaluar el rendimiento del método propuesto, éste se compara con dos métodos tradicionales para estimación de TDOA presentados en la sección 2.4: Energía acumulativa y correlación cruzada. La comparación se realiza primero para una fuente activa y los resultados se presentan en la Tabla 4.7. En esta tabla se pueden ver, para cada posición de la Tabla 4.6, los valores reales de los TDOA, calculados a partir de las distancia entre cada fuente y los sensores y la velocidad de propagación de la onda acústica, y los resultados obtenidos por cada método. Se puede comprobar como todos los métodos estiman los TDOA con valores muy cercanos al real.

En la Tabla 4.8 se muestran los valores comparativos de los TDOA obtenidos por los tres métodos cuando están activas las dos fuentes. En este caso el algoritmo ICA-Amari, además de estimar los valores más cercanos a los valores reales, proporciona los TDOA para las dos fuentes. En cambio, los métodos tradicionales no tienen en su estructura una manera de estimar TDOA para dos fuentes. Cuando se utiliza el par de señales de los dos sensores sólo pueden encontrar un TDOA y, como se muestra en la Tabla 4.8, además en ocasiones se alejan de los valores reales. En esta tabla se ha rellenado con N/D las posiciones en las que cada método no proporciona resultados o éstos están fuera de los límites posibles.




Figura 4.26. Filtros para la estimación de los TDOA entre los sensores x_1 y x_2 cuando las dos fuentes están activas. En w_{12} se muestra el TDOA τ_{21} que representa el retardo de s_2 en x_2 respecto a x_1 . En w_{21} se muestra el TDOA τ_{12} que representa el retardo de s_1 en x_1 respecto a x_2 . U.A: Unidades arbitrarias.

Tabla 4.7. Comparativa entre los métodos Amari, energía acumulada y correlación cruzada con una fuente activa (s_1).

Posición	Par de sensores	TDOA (μs)			
		Real	ICA	Energía	Correlación
1	X1-X2	0.46	0.5	0.6	0.5
	X1-X3	2.29	2.3	2.4	2.3
2	X1-X2	1.50	1.6	1.8	1.5
	X1-X3	3.32	3.1	3.4	3.3
3	X1-X2	2.13	2.0	2.1	2.2
	X1-X3	4.32	4.2	4.2	4.2

Tabla 4.8. Comparativa entre los métodos ICA, energía acumulada y correlación cruzada con dos fuentes activas (s_1 y s_2).

Posicion	Fuente	Par de sensores	TDOA (μs)			
			Real	ICA	Energía	Correlacion
1	S1	X1-X2	0.46	0.5	1.1	N/D
		X1-X3	2.29	2.3	N/D	3.4
	S2	X1-X2	0.76	0.8	0.6	0.7
		X1-X3	1.37	1.4	N/D	N/D
2	S1	X1-X2	1.5	1.6	2.5	1.4
		X1-X3	3.32	3.1	4.1	N/D
	S2	X1-X2	1.74	1.8	N/D	2.3
		X1-X3	1.33	1.3	N/D	N/D
3	S1	X1-X2	2.13	2.0	N/D	2.2
		X1-X3	4.32	4.2	3.1	5.1
	S2	X1-X2	1.76	1.7	1.5	N/D
		X1-X3	1.26	1.3	N/D	N/D

4.7. Conclusiones del capítulo

En este capítulo se realiza la detección de acústica de multiples fuentes de DP, específicamente DP internas y superficiales. Se realizó aplicando el algoritmo ICA-Amari modificado para tratar mezclas en ambiente reales.

En este capítulo se presentaron dos tipos de experimentos: Uno donde el proceso de mezclado es totalmente simulado en MATLAB y otro donde las mezclas son generada desde señales acústicas reales. Para el primer experimento se utilizaron señales previamente registradas desde defectos que generaban DP internas y superficiales. En la simulación del mezclado se verificó que las señales en los sensores cambiaban sus características en tiempo y frecuencia lo que las convertía en señales muy diferentes a las originales. Con la aplicación del algoritmo se logró generar señales que contenían las mismas características en tiempo-frecuencia que las originales. En el experimento con señales acústicas reales se obtuvieron las mismas conclusiones.

Es importante señalar que cada señal estimada es colocada en un canal diferente y de esta manera el algoritmo de manera automática logra realizar la clasificación de los dos tipos. Cada canal puede ser visto como el mapa de una clase de descarga. El éxito de la identificación ha sido corroborado con un análisis de correlación entre las huellas de energía de las fuentes originales y estimadas resultando en valores cercano a la unidad, indicando similitud entre las huellas.

El algoritmo ICA-Amari contiene varios parámetros de operación: tasa de aprendizaje, función de activación, longitud del filtro, numero de iteraciones y condición de parada. Estos valores fueron analizados para evaluar su efecto en el rendimiento del algoritmo. Se estableció que el importantes es el valor inicial de la tasa de aprendizaje el cual determina la estabilidad y velocidad del algoritmo.

Como último tema fue presentado un nuevo método para la estimación de TDOA en un ambiente de multiples fuentes de descargas. En este caso son utilizado los pesos utilizados por el algoritmo para la separación. Estos pesos contienen información espacial que permite identificar el TDOA de cada fuente. El método fue probado con mezclas acústicas reales generadas por DP internas y superficiales y sus resultados fueron comparados con resultados de métodos tradicionales de estimación de TDOA. Estos últimos fallaron ya que no contienen en su estructura una manera de tratar con emisiones generadas por más de una fuente de descarga.

El análisis de los resultados de identificación y localización con el método acústico de detección de DP y ICA serán utilizados como referencia en el capítulo 5 en el cual, se trabaja con DP reales que no pueden ser controladas como en el experimento presentado en este capítulo.

CAPITULO 5

5. ICA para la detección electromagnética de múltiples DP

Las descargas generadas por los defectos en los aislantes emiten radiación electromagnética, principalmente en el rango UHF, la cual puede ser detectada por sensores de tipo antena. Los métodos actuales para detección y localización UHF asumen la presencia de una sola fuente de DP. Sin embargo, siempre existe la posibilidad de más fuentes activas y ruido perturbando la señal detectada. En el capítulo anterior se presentó el algoritmo ICA-Amari extendido para mezclas convolutivas como herramienta para para tratar con el efecto de la mutua interferencia entre señales acústicas provenientes de dos fuentes artificiales de DP posibilitando la identificación. En este capítulo, el algoritmo es aplicado a mezclas de señales electromagnéticas desde dos fuentes reales de DP, las cuales son detectadas por antenas UHF y posteriormente aplicadas algoritmo para realizar la identificación y la localización de estas fuentes.

5.1. Generación de mezclas de emisiones electromagnéticas

A diferencia del montaje experimental para la detección acústica, en este experimento las fuentes no son controladas. No es posible conocer a priori el inicio de cada pulso de DP ni los intervalos entre ellos. Sólo se puede controlar la tensión y la posición espacial de las fuentes. Además, no se generan dos tipos diferentes de DP como en el experimento acústico, los cuales presentaban características diferentes en tiempo y frecuencia. En este experimento las fuentes son del mismo tipo, lo que genera señales con características muy similares en tiempo y frecuencia. El experimento se diseña de esta manera con el objetivo de evaluar el algoritmo ICA-Amari en un ambiente más difícil donde las señales tienen formas de onda muy similares que pueden ser confundidas con señales provenientes desde una sola fuente. Este caso puede ser encontrado en un transformador u otros equipos en una subestación, donde existe la posibilidad de varias fuentes de DP del mismo tipo, pero

totalmente independientes. Por ejemplo: dos defectos generando DP superficiales en cada terminal de alta tensión del transformador.

5.1.1. Montaje experimental

En la Figura 5.1 se muestra el montaje del experimento. Consiste en dos objetos de ensayo que actúan como fuentes de generación de descargas superficiales. Cada objeto de ensayo consiste en una lámina de polietileno colocada entre electrodos cilíndricos metálicos. Estos producen descargas superficiales entre la interface del electrodo y la lámina dieléctrica. Esta lámina está colocada sobre el piso del laboratorio el cual está cubierto por un plano de aluminio que eléctricamente funciona como la referencia de tierra. La radiación electromagnética de las DP es detectada por dos antenas UHF. Los sensores son antenas monopolos de 10 centímetros de longitud que tienen una respuesta resonante a 750 MHz. Con estas antenas es posible adquirir señales de todo tipo de DP a una distancia hasta de 2 metros sin el uso de un amplificador de banda ancha. En la Figura 5.2 se muestra una imagen más amplia de estas antenas. Las antenas están conectadas por medio de cables coaxiales de igual longitud a un osciloscopio de cuatro canales marca Tektronix modelo DPO7254 de 8 bit de resolución y 40 GS/s de frecuencia de muestreo. Para este osciloscopio cada canal tiene una frecuencia de muestreo de 10 GS/s lo que ofrece una resolución temporal de 0.1ns por cada muestra y una espacial de 3 centímetros asumiendo la velocidad de la luz para las ondas electromagnéticas.

El montaje experimental ofrece la posibilidad de colocar las antenas en diferentes posiciones al igual que las fuentes. Se realizaron pruebas con varias posiciones con el objetivo de obtener pulsos muy definidos, sin embargo, se encontró que la forma de onda de las emisiones dependía de la posición de la antena con respecto a la fuente. Cuando la antena estaba debajo del plano de la fuente, la forma de onda además del pulso inicial contenía gran cantidad de oscilaciones de casi el mismo tamaño del primer pulso que disminuían con el tiempo. A medida que la antena era puesta al nivel del plano o por encima de éste, las oscilaciones disminuían y el pulso tenía mejor definición. Por esta razón se decidió colocar las antenas por encima del plano horizontal de las fuentes. En la Figura 5.3 se muestran un ejemplo de las coordenadas de las fuentes s_1 , s_2 y las antenas x_1 , x_2 utilizadas en uno de los experimentos. Aunque las fuentes y las antenas no están a una misma altura están contenidas en un mismo plano imaginario. Por otro lado, las antenas están ubicadas de tal manera que detectan en el campo de distancia lejana de la

actividad electromagnética de las DP que para el experimento debe ser mayor a los 50 centímetros.

En las pruebas se utilizó como referencia la antena x_1 . Cada vez que el nivel de tensión sobrepasaba el valor 10mV en este sensor se iniciaba el registro para los dos canales, el cual era de un tiempo de 100 η s. Es importante señalar que el osciloscopio tiene una función pre-trigger el cual graba en memoria un intervalo de tiempo antes que el pulso sobrepase el umbral preestablecido. Esto asegura el registro de toda la señal en la antena x_2 . Para el experimento este intervalo era de 10 η s.




Figura 5.1. Montaje del experimento para generación de emisiones electromagnéticas de dos fuentes de descarga superficial.




Figura 5.2. Antena monopolo utilizada para la detección de las señales UHF. Consiste en un conductor de cobre de 10 centímetros soldado al pin de metal del cable coaxial.




Figura 5.3. Posiciones de las fuentes y los sensores. Las coordenadas están en centímetros.

5.1.2. Generación de mezclas

Una vez montado el experimento se procedió a activar cada fuente individualmente para verificar que se generaba una actividad estable a un mismo nivel de tensión para las dos fuentes. Esto se consiguió para todos los experimentos con un nivel de tensión de 6kV. Se estableció una referencia de disparo 10mV en el osciloscopio. Cada vez que se detectaba una tensión mayor a este valor el osciloscopio grababa la señal con una duración de 100 ηs igual a 1000 muestras. Esta ventana de tiempo fue escogida después de evaluar

ventanas de menor y mayor valor. En el caso de ventanas de menor valor en algunos casos el pulso no era grabado de manera completa, es decir con todas las oscilaciones. Con una ventana mayor se registraba el pulso más una gran cantidad de ruido innecesario para el análisis. Se verificó que con ventanas hasta de $1 \mu s$ sólo se detectaba un pulso. Aumentar la ventana de registro a un mayor valor resultaba en el registro de más pulsos, sin embargo, no se escogió estas ventanas debido a la gran cantidad de muestras que se generaban lo que hace más lento el procesamiento. Con una ventana $100 ns$ se aseguró que se registre un pulso completo de DP. Es importante resaltar que ninguna de estas pruebas se dio el evento en el cual dos pulsos quedaban en una misma ventana de tiempo, de esta manera no hubo superposición entre pulsos consecutivos debido a una sola fuente.

En Figura 5.4 se muestran dos señales típicas de los objetos de ensayo correspondientes a la fuente superficial s_1 y a la fuente superficial s_2 , respectivamente. Las señales son muy similares en forma de onda, amplitud y duración. Para verificar esto se calculó el coeficiente de correlación Pearson entre las dos señales resultando en un valor de 0.94. Esta similitud se observa también en un análisis de huellas de energía obtenidas con la transformada Wavelet de las dos señales. Se utilizó la wavelet madre Daubechies de orden 8 con 6 niveles de descomposición. En la Figura 5.5 se muestra la distribución de energía en cada nivel. El coeficiente de correlación Pearson da un resultado de 0.95 entre los dos patrones Wavelet de estas señales.




Figura 5.4. Ejemplo de las señales electromagnéticas generadas en el experimento. (a) Señal desde el objetivo de ensayo s_1 y (b) Señal desde el objeto de ensayo s_2 .




Figura 5.5. Distribución promedio de energía por para cada nivel de descomposición Wavelet para cada grupo de 100 señales electromagnéticas desde las fuentes superficiales s_1 y s_2 , respectivamente. La desviación estándar para cada nivel se muestra en negro y corresponde a 2% para cada fuente.

Estas dos señales son generadas por fuentes independientes colocadas en dos diferentes posiciones. No existe relación entre ellas, sin embargo, tienen características muy similares tanto en tiempo como en frecuencia, lo que hace muy difícil la identificación. Normalmente, el juicio sería asumir que son generadas por una sola fuente de DP.

5.2. Filtrado del ruido

En los experimentos las señales detectadas son afectadas por fuentes de ruido electromagnético. Para limitar su efecto en los resultados se procedió a aplicar una técnica de filtrado Wavelet. Esta técnica permite reducir el ruido, pero preservando la forma de onda de interés.

Se realizó un análisis del tipo de ruido de tal forma que se logró identificar que bandas de frecuencias eran las más afectadas y que tipo de filtrado Wavelet era el óptimo. Para el análisis se registró el ruido presente sin DP y se caracterizó. Se pudo determinar que existían señales en el rango VHF y UHF tales como radio FM, televisión digital, telefonía móvil GSM y señal UTMS. En la Figura 5.6 se muestra el espectro de ruido afectando las señales detectadas por las antenas. La señal de Radio FM se encuentra entre los 88-108 MHz, las señales de TV en el rango de 414-882 MHz, las señales de móviles GSM en 900 MHz y 1800 MHz, UTMS en los 2110-2170 MHz. Para la detección del ruido se utilizó el mismo tipo de antena que el utilizado para las DP. Se tomaron 100 ventanas de

1 ms de señal y se promediaron. Esto se realizó en diferentes días resultando en similares valores a los presentados en la gráfica de la Figura 5.6.




Figura 5.6. Señales de ruido afectando las señales detectadas en las antenas.

En la Tabla 5.1 se muestra el porcentaje promedio de energía por nivel de 100 pulsos de DP superficial s_1 medidos con la antena x_1 . Los niveles D2 y D3 contiene la mayor parte de la energía de los pulsos. De esta manera, si se aplica el filtrado Wavelet a la señal para atenuar la energía de los niveles de energía D1, D4, D5, D6 y A6 los cuales contiene poca información del pulso de DP, se atenuará el ruido. Para el filtrado Wavelet se utiliza una descomposición Wavelet de 6 niveles con una Wavelet madre Daubechies 8. Este filtrado es realizado para todas las señales antes de aplicarlas al algoritmo.

Tabla 5.1. Descomposición Wavelet de la señal de DP superficial de la gráfica (a) Figura 5.4. Se ha colocado para cada nivel de energía el tipo de ruido que la afecta en la medición.

D	Intervalo (MHz)	Energía (%)	Ruido
D1	2500 – 5000	3.5	WiFi
D2	1250 – 2500	52.4	GSM, UMTS, WiFi
D3	625 - 1250	20.3	TV, GSM
D4	312 – 625	9	TV
D5	156 - 312	7.1	DAB
D6	78 – 156	3.1	FM
A6	0 – 78	4.6	Inductivo

5.3. Separación e identificación utilizando el algoritmo ICA-Amari

Para realizar la separación las señales registradas por las antenas, se aplica el algoritmo ICA-Amari adaptado para mezclas convolutivas. Para registrar las señales se procede a activar las dos fuentes a la vez y a registrar las señales con las antenas x_1 y x_2 .

Se utilizó como referencia la antena x_1 . Cada vez que el nivel de tensión sobrepasaba un valor de 10mV se registraban 10 μ s. Este tiempo fue suficiente para registrar el pulso de la descarga en los dos canales. Un ejemplo de los pulsos registrados por cada antena es mostrado en las gráficas (a) para x_1 y (b) para x_2 de la Figura 5.7. Los parámetros para el algoritmo son mostrados en la **¡Error! No se encuentra el origen de la referencia.** La longitud del filtro, $L = 50$, se escogió para cubrir un TDOA máximo de 5 ns o 150 centímetros en su equivalente valor de distancia. Este valor fue suficiente para cubrir los TDOA de las fuentes. La tasa de aprendizaje, $\eta = 0.0001$ fue escogida después de varias pruebas. Una mayor generaba inestabilidad y una menor generaba una convergencia lenta. Los demás parámetros, número de iteraciones y valor de parada se establecieron de manera empírica. Un ejemplo de las estimaciones del algoritmo y_1 y y_2 son mostrados en las gráficas (d) y (b) de la Figura 5.7, respectivamente. Para obtener estos resultados el algoritmo fue detenido en 50 iteraciones. Las señales x_1 y x_2 contienen seis pulsos cada una y después del procesado por el algoritmo la estimación y_1 tiene solo dos pulsos y la estimación y_2 cuatro pulsos. Además, ninguno de los pulsos de y_1 coinciden temporalmente con los pulsos de y_2 .

Tabla 5.2. Parámetros para el algoritmo ICA-Amari para separación de dos fuentes.

Parámetro	Valor con mezclas reales
Longitud del filtro	$L = 50$
Tasa de aprendizaje	$\eta = 0.0001$
Número de iteraciones	50
Condición de parada	0.01

De estos resultados se puede concluir que el algoritmo realiza un trabajo sobre las mezclas, sin embargo, es necesario más evidencia que nos permita concluir si está separando. En la sección 4.6 se propuso un método para la localización de dos fuentes de descarga parciales utilizando los pesos estimados por el algoritmo. Se utilizan el mismo procedimiento para verificar si los pesos w_{12} y w_{21} estimados por el algoritmo contienen los TDOA de las fuentes s_1 y s_2 .

Los TDOA de cada fuente s_1 y s_2 se pueden obtener ya que se conocen las distancias entre cada fuente y los sensores. Se calculan tomando como referencia el sensor x_1 , la velocidad de la luz que es igual 30 centímetros por nanosegundos y la frecuencia de

muestreo de 10GS/s. La distancia entre la fuente s_1 y el sensor x_2 es igual a 120.1 cm. A la señal le toma desde la fuente hasta el sensor $\tau_i = d/c$, donde i es el índice de el sensor, d es la distancia en centímetros y c es la velocidad de la luz. Aplicando esta formula obtenemos $\tau_2 = 4.0$ ns. Ahora, se calcula el tiempo de llegada desde la fuente s_1 al sensor x_1 que es $\tau_1 = 2.23$ ns, utilizando la distancia de 69.9 cm entre estos dos elementos. El TDOA de la fuente s_1 es igual a la diferencia entre estos dos tiempos de llegada, $\tau_{s1} = \tau_1 - \tau_2 = 1.77$ ns, que es equivalente a 17.7 muestras. Este mismo procedimiento se sigue para calcular el TDOA de la fuente s_2 , que es igual a $\tau_{s2} = 1.81$ ns, equivalente a 18.1 muestras.




Figura 5.7. Ejemplo de señales electromagnéticas registradas por los sensores y de las estimadas por el algoritmo ICA-Amari. (a) Señal en el sensor x_1 , (b) Señal en el sensor x_2 , (c) Señal y_1 estimada (d) Señal y_2 estimada.

En la Figura 5.8 se muestran la gráfica de los pesos w_{12} y w_{21} estimados. Los valores máximos se observan en las muestras 17 y 18 para w_{12} y w_{21} , respectivamente. Se tiene

que restar una muestra en cada grafica para obtener el valor del TDOA. Se puede concluir que el w_{12} contiene el TDOA de la fuente s_1 y el TDOA de la fuente s_1 , está en el peso w_{21} . Ya que cada peso funciona como un filtro que elimina la mutua interferencia, los parámetros de cada peso son utilizados para eliminar la señal que interfiere. En este ejemplo los parámetros del peso w_{12} son utilizados para eliminar la señal s_2 que llega al sensor x_1 desde la fuente s_1 y w_{21} para eliminar la fuente s_2 en la señal del sensor x_2 . De esta manera y_1 tiende a la fuente s_1 y y_2 a la fuente s_2 . Con este análisis, se puede concluir que el algoritmo separa las mezclas en las dos fuentes identificando dos fuentes de descarga parcial del mismo tipo, en este caso DP superficiales.




Figura 5.8. Pesos w_{12} (a) y w_{21} (b) para la estimación de los TDOA. Se ha colocado una fleja roja para indicar la diferencia temporal desde la muestra inicial a la muestra con la máxima magnitud. Para el peso w_{12} la diferencia es de 17 muestras y para el peso w_{21} la diferencia es de 18 muestras.

Es importante destacar que la validación del algoritmo se puede realizar se cuenta con los TDOA reales de cada fuente sin embargo en situaciones en ambientes reales es muy difícil calcularlos, siendo este un requerimiento inherente de un sistema automático de localización. Sin embargo, la evaluación presentada demuestra que el algoritmo puede separar y identificar cada fuente de DP además de estimar sus TDOA.

5.4. Conclusiones del capítulo

En este capítulo se ha tratado el tema de la identificación y localización de múltiples fuentes de DP utilizando el método de detección electromagnético. Se han presentado los resultados de experimentos donde se generan mezclas de emisiones electromagnéticas

que son detectadas por antes en el rango UHF. Las señales de los experimentos provienen de dos fuentes de DP superficiales con el objetivo de probar el algoritmo ICA-Amari con señales del mismo tipo que contienen características muy similares en tiempo y frecuencia, pero son independientes entre sí. Se generaron señales desde las dos fuentes de DP que fueron detectadas por los dos sensores. Estas señales que son mezclas desde las dos fuentes fueron estudiadas y se logró identificar además de la mutua interferencia varias señales de ruido que las afectaban en distintas bandas de frecuencia. Para disminuir el efecto del ruido se aplicó un filtro basado en la transformada Wavelet y las señales resultantes fueron aplicadas al algoritmo. Los resultados se estudiaron y se concluyó que el algoritmo separa las señales en las dos fuentes originales. Esto se validó calculando los TDOA de cada fuente y comparándolos con los TDOA extraídos desde los pesos estimados del algoritmo.

CAPÍTULO 6

6. Aportaciones de la tesis, trabajo futuro y publicaciones

6.1. Aportaciones

En esta tesis doctoral se propone un método para enfrentar el problema de múltiples fuentes de descarga creando mezclado de señales en los sensores; condición que afecta el desempeño de los algoritmos tradicionales para identificación y localización, que están basados en la presencia de una sola fuente de DP. El método propuesto, basado en ICA, recupera la forma de onda original de cada fuente y de manera automática las agrupa posibilitando la identificación. Esto ha sido validado utilizando el método acústico y electromagnético arrojando resultados muy prometedores.

El nuevo método está basado en una ICA, que esta basado en una robusta base matemática y estadística y que se aplica en ambientes reales con éxito. En esta tesis se aplica por primera vez ICA a la detección de múltiples DP en un ambiente real donde las señales detectadas están afectadas por la mutua interferencia, reflexiones y reverberación. La propuesta aborda es problema con el algoritmo ICA-Amari extendido para mezclas convolutivas, el cual además de la separación de las mezclas en las señales originales, lo realiza de forma automática.

Otro aporte importante es la obtención automática de los TDOA, fundamentales para la localización de las fuentes de DP. El algoritmo estima pesos que son filtros que utiliza para eliminar la señal que interfiere y que son los TDOA de esta señal. De esta manera, el resultado es información útil para la localización. Es importante destacar, que para el algoritmo no es necesario colocarles umbrales, simplemente la estimación se basa en la búsqueda de la independencia estadística el cual es un marco general que no necesita referencias. Esta referencia esta implícitas en la estructura y regla de aprendizaje del algoritmo.

6.2. Trabajo futuro

Toda investigación siempre esta incompleta y el deseo de conclusión es el motor que incentiva continuarla. Esta tesis es el genesis de varias líneas de investigación y problemas abiertos:

- 1) ¿Es posible aplicar ICA para separar múltiples fuentes DP, pero utilizando detección con un sólo sensor? Esta línea de investigación se esta explorando hace varios años, pero en otros campos como la biomédica o acústica. Tiene aplicación para todos los métodos de detección de DP estudiados en la tesis, sin embargo, es más interesante para el convencional donde normalmente sólo se tiene acceso a un sensor.
- 2) Aplicación de la propuesta en equipos reales. En la tesis sólo se ha realizado pruebas en plataformas de ensayos que mantienen un ambiente controlado en la generación de las DP. Es importante llevar la propuesta al campo y ofrecer una solución en ingeniería con la posibilidad de patentar.
- 3) La validación de los resultados del algoritmo para el mezclado de señales electromagnéticas es manual y necesita tener a mano los TDOA originales. En campo esto es muy difícil de conseguir por lo que es necesario idear un mejor método de validación de resultados. Se puede intentar con máquinas de aprendizaje, tales como las basadasn en Maquinas de Vectores Soporte o SVM (Support Vector Machine) o redes neuronales. En cualquiera de los casos, siempre es necesario obtener señales patrones para comparar con los resultados.
- 4) Localizacion automática. En este caso es necesario aumentar la cantidad de sensores acústicos o UHF de tal forma de posibilitar la localización en tres dimensiones. Sin embargo, esto tiene un desafío que debe ser superado si se quiere aplicar el algoritmo a un equipo comercial. En este trabajo siempre se pudo calcular los TDOA y de esta manera comprobar si era de una u otra fuente. En un ambiente real esto no es posible y ni siquiera práctico. La localización automática requiere que de manera natural los TDOA sean identificados y asociados a cada fuente. Actualmente, este es un problema abierto en el campo de ICA para ambientes reales.

6.3. Publicaciones

- Ruiz-Llata, M., Guarnizo, G. y Boya, C. “Embedded power quality monitoring system based on Independent Component Analysis and SVMs”, The 2011 International Joint Conference on Neural Networks (IJCNN), páginas 2229-2234, San Jose, California, 2011.
- Boya, C., Posada, J., Rubio-Serrano, J, Posada, J., Garcia-Souto, J.A. y Ruiz-Llata, M. “Instrumentation system for acoustic detection of multiple sources of partial discharges”, IEEE International conference on industrial technology, Athenas, Greece, páginas 579-584, 2012.
- Boya, C., Ruiz-Llata, M., Posada, J. y Garcia-Souto, J.A. “Identification of Multiple Partial Discharge Source using Acoustic Emission Technique and Blind Source Separation”, IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 22, No. 3, páginas 1663-1673, 2015a.
- Boya, C., Rojas-Moreno, M.V., Ruiz-Llata, M. y Robles, G. “Location of Partial Discharges Sources by Means of Blind Source Separation of UHF signals”, IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 22, No. 4, 2015b.

CAPITULO 7

7. Referencias

- Abdel-Galil, T., Hegazy, Y.G., Salama, M. M. A., Bartnikas R. “Partial discharge pulse pattern recognition using Hidden Markov Models”, IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 11, No 4, páginas 715-273, 2004.
- Agarwal, V. K., Banfor, H. M., Bernstein, B. S., Brancato, E. L., Fouracre, R. A., Monanari, G. C., Parpal, J. L., Seguin, J. N, Ryder, D.M. y Tanaka J., “The Mysteries of Multifactor Aging”, IEEE Electrical Insulation Magazine, Vol. 1, No. 3, páginas 37-43, 1995.
- Albarracin, R. Medida de descargas parciales en radiofrecuencia. Tesis Doctoral, Universidad Carlos III de Madrid, 2014.
- Albera, L., Ferreol, A., Cosandier-Rimele, D., Merlet, I. y Wendling, F. “Brain source localization using a fourth-order deflation scheme”, IEEE Transaction on Biomedical Engineering., Vol.55, paginas 490–501, 2008.
- Alton, F. The master handbook of acoustic. Cuarta Edición. 2001.
- Amari, S., Cichocki A. y Yang H. H. "A new learning algorithm for blind signal separation", Advances in neural information processing systems, páginas 757-763, 1996.
- Aschenbrenner D. y Kranz, H.G. “On line PD measurements and diagnosis on power transformers”, IEEE Transactions on Dielectrics and Electrical Insulation., Vol. 12, No. 2, páginas 216-222, 2005.
- Austen, A.E.W y Whitehead, S., "Discharges in insulation under alternating current stresses", Journal IEEE, Vol. 88, Part II, 1941, páginas. 18-22.
- Back, A.D. y Weigend, A.S. “A first application of independent component analysis to extracting structure from stock returns”, International journal of neural systems, Vol. 8, No. 4, pp. 473-484, Aug. 1997.
- Balanis, C.A. Antenna Theory: Analysis and Desing. Wiley Interscience, 3ª edición, 2005. ISBN 047166782X.

- Barros, A.K., Mansour, A. y Ohnishi, N. "Removing artefacts from electrocardiographic signals using independent component analysis", *Neurocomputing* 22 (1998) 173–186.
- Bartnikas, R. y Levi, J. "A simple pulse-height analyzer for partial discharge rate measurements", *IEEE Trans on Instrumentation and Measurement*, Vol. 18, 1969, páginas 341-345
- Barnikas, R., MacMahon, E. y ASTM. Corona measurement and interpretation. ASTM special technical publication. ASTM Committee D-9 on Electrical Insulating Material, 1979.
- Bartnikas, R. "Partial Discharges. Their Mechanism, Detection, and Measurement", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 9, páginas 763-808, 2002.
- Bell, A. J. y Sejnowski, T. J. "An Information maximization approach to blind separation and blind deconvolution," *Neural Computation*, Vol. 7, páginas 1129-1159, 1995.
- Boczar, T. "Identification of a Specific Type of Partial Discharges form Acoustic Emission Frequency Spectra", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 8, No 4, páginas 598-606, 2001.
- Boczar, T. y Zmarzly, D. "Application of wavelet analysis to acoustic emission pulses generated by partial discharges", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 11, No. 3, páginas 433-449, 2004.
- Boczar, T., Burocki, S, Cichon A. y Zmarzly D. "Application possibilities of artificial neural networks for recognizing partial discharges measured by the acoustic emission", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 16, No. 1, páginas 2014-223, 2009.
- Boczar, T., Cichon A. y Borucki, S. "Diagnostic expert system of transformer insulation systems using the acoustic emission method", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 21, No. 2, páginas 854-865, 2014.
- Boggs, S. A., Ford G. L. y Madge, R. C. "Coupling devices for the detection of partial discharges in gas-insulated switchgear", *IEEE Transaction on power apparatus and systems*, Vol. PAS-100, No 8, páginas 3969-3973, 1981.
- Boggs, S.A. y Stone, G.C, "Fundamental Limitations in the Measurement of Corona and Partial Discharge", *IEEE Transactions on Electrical Insulation*, Vol. EI-17, No. 2, páginas 143-150, 1982.

- Boya, C., Posada, J., Rubio-Serrano, J, Posada, J., Garcia-Souto, J.A. y Ruiz-Llata, M. "Instrumentation system for acoustic detection of multiple sources of partial discharges", IEEE International conference on industrial technology, Athenas, Greece, páginas 579-584, 2012.
- Boya, C., Ruiz-Llata, M., Posada, J. y Garcia-Souto, J.A. "Identification of Multiple Partial Discharge Source using Acoustic Emission Technique and Blind Source Separation", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 22, No. 3, páginas 1663-1673, 2015a.
- Boya, C., Rojas-Moreno, M.V., Ruiz-Llata, M. y Robles, G. "Location of Partial Discharges Sources by Means of Blind Source Separation of UHF signals", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 22, No. 4, 2015b.
- Cacciari M., Contin A., Rabach, G., y Montanari, G. C. "Diagnosis of practical insulation systems by partial discharge measurments in the presence of multi-dicharge phenomena", en Conference on Electrical Insulation and Dielectric Phenomena, Pennsylvania, USA, 1993.
- Cacciari M., Contin A., y Montanari, F. "Use of a mixed-Weibull distribution for the identification of PD phenomena" IEEE Transactions on Dielectrics and Electrical Insulation Vol. 2, No.6, páginas 1166–1179, 1995.
- Cacciari M. y Contin A. "Identification and separation of two concurrent partial discharge phenomena", en Conference on Electrical Insulation and Dielectric Phenomena, San Francisco, USA, 1996.
- Cardoso, J. F., "Fetal electrocardiogram extraction by source subspace separation", in: IEEE International Conference on Acoustics Speech and Signal Processing, 1998, pp. 1941–1944.
- Cardoso, J. F. "The three easy routes to independent component analysis: contrasts and geometry", en Proceedings of ICA 2001, San Diego, USA, 2001.
- Cavallini, A., Montanari, G., Contin, A. y Pulletti, F. "A new approach to the diagnosis of solid insulation systems based on PD signal inference." IEEE Electrical Insulation Magazine, Vol. 19, No.2, páginas 23–30, 2003.
- Cavallini, A., Montanari, G.C., Pulletti, F.y Contin, A. "A new methodology for the identification of PD in electrical apparatus: properties and applications", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 12, No. 2, páginas 203-215, 2005.

- Cavallini, A., Ramos, C.G.A., Montanari, G.C., Saad H. y Tozzi, M. "UHF detection of PD in power transformers: The influence of disturbances", 2011 Annual Report Conference on Electrical Insulation and Dielectric Phenomena (CEIDP), páginas 436-439, 2011a.
- Cavallini, A., Ramos, C.G.A., Montanari, G.C., Rubio-Serrano, J. y Garcia-Souto, J.A. "Comparison of ultrasonic, electrical and UHF characteristics of partial discharge emission in oil/paper insulation systems", 2011 Annual Report Conference on Electrical Insulation and Dielectric Phenomena (CEIDP), Cancun, páginas 440-443, 2011b.
- Chan, Y. T. y Ho, K. C. "Simple and Efficient Estimator for Hyperbolic Location", IEEE Transactions on Signal Processing, Vol. 42, No. 8, pp. 1905-1915, August 1994.
- Chang, C., Chang, C.S., Hoshino, T., Hanai, M. y Kobayashi, N. "Source classification of partial discharge for gas insulated substation using waveshape pattern recognition", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 12, No 2, páginas 374-386, 2005.
- Chang, C.S., Jin, J., Chang, C., Hoshino, T., Hanai, M. y Kobayashi, N. "Online source recognition of partial discharge for gas insulated substations using independent component analysis", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 13, No. 4, páginas 892-902, 2006.
- Charkani, N. y Deville, Y. "Self-adaptive separation of convolutively mixed signals with a recursive structure. Part II: Theoretical extensions and application to synthetic and real signals", Signal Processing 75 (1999) 117–140.
- Chen, J., Benesty, J. y Huang, Y.A. "Time Delay Estimation in Room Acoustic Environments: An Overview", EURASIP Journal on Advances in Signal Processing, Vol. 2006, paginas 1-19, 2006.
- Cherry, E. C. "Some experiments on the recognition of speech with one and with two ears," Journal of Acoustical Society of America, Vol. 25, No. 5, páginas 975–979, 1953.
- Choi, S., Hong, H., Glotin, H. y Berthommier, F. "Multichannel signal separation for cocktail party speech recognition: a dynamic recurrent network", Neurocomputing, Vol. 49, paginas 299-314, 2002.
- Cichocki A. y Amari S. "Adaptive blind signal and image processing: learning algorithms and applications", John Wiley & Sons; 2002 Jun 14.

- Cleary, G.P. y Judd, M.D. "UHF and current pulse measurements of partial discharge activity in mineral oil", IEE Proceedings Science, Measurement and Technology, Vol. 153, No. 2, páginas 47-54, 2006.
- Coenen, S, Tenbohlen, S. "Location of PD Sources in Power Transformers by UHF and Acoustic Measurements", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 19, No. 6, páginas 1934-1940, 2012.
- Comon, P. "Independent component analysis, A new concept?", Signal Processing, Vol. 36, pp. 287-314, 1994.
- Comon, P., Jutten, C. "Introduction", en Handbook of Blind Source Separation. Independent Component Analysis and Applications. Primera edición, Oxford, UK, Cap. 1, 2010.
- Comon, P., Jutten, C. "Information", en Handbook of Blind Source Separation. Independent Component Analysis and Applications. Primera edición, Oxford, UK, Cap. 2, 2010.
- Comon, P., Jutten, C. "Application to telecommunications", en Handbook of Blind Source Separation. Independent Component Analysis and Applications. Primera edición, Oxford, UK, Cap. 17, 2010.
- Comon, P., Jutten, C. "Biomedical applications", en Handbook of Blind Source Separation. Independent Component Analysis and Applications. Primera edición, Oxford, UK, Cap. 18, 2010.
- Comon, P., Jutten, C. "Audio applications", en Handbook of Blind Source Separation. Independent Component Analysis and Applications. Primera edición, Oxford, UK, Cap. 19, 2010.
- Contin, A., Montanari, G.C. y Ferraro, C. "PD source recognition by Weibull processing of pulse height distributions", IEEE Trans. Dielectr. Electr. Insul., Vol. 7, No. 1, páginas 48-58, 2000.
- Contin, A., Cavallini, A., Montanari, G.C., Pasini, G. y Puletti, F. "Digital detection and fuzzy classification of partial discharge signals", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 9, No. 3, páginas 335-348, 2002.
- Contin, A., y Pastore, S. "Classification and Separation of Partial Discharge Signals by Means of their Auto-correlation Function Evaluation", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 16, No. 6, páginas 1609-1622, 2009.
- Del Castillo, M. D., Serrano, J. I., Ibáñez, J. y Barrios, L. J. "Metodología para la Creación de una Interfaz Cerebro-Computador Aplicada a la Identificación de la Intención

- de Movimiento”, *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 8(2), 93-102, 2011.
- Douglas, S.C., Sawada, H. y Makino, S. “Natural gradient multichannel blind deconvolution and speech separation using causal FIR filters”, *IEEE Transactions on Speech and Audio Processing* 13 (2005) 92–104.
- Ehlers, F. y Schuster, H.G. “Blind separation of convolutive mixtures and an application in automatic speech recognition in a noisy environment”, *IEEE Transactions on Signal Processing* 45 (1997) 2608–2612.
- Fabiani, D., Cavallini, A. y Montanari, G.C. “A UHF Technique for Advanced PD Measurements on Inverter-Fed Motors”, *IEEE Transactions on Power Electronics*, Vol. 23, No 5, páginas 2546-2556, 2008.
- Foy, W. H. “Position-location solutions by Taylor-series estimation”, *IEEE Transaction on Aerospace Electronic System*, Vol. AES-12, pp. 187-194, 1976.
- Gao, J., Xu Z., y Nandi, A. K. "Independent component analysis for multiple-input multiple-output wireless communication systems." *Signal Processing* 91.4 (2011): 607-623.
- Gaxiola, E. H. R. y Wetzler, J. M. "Partial discharge modelling and measurements on micrometer voids in solid dielectrics", 7th Intern. Conf. Dielectric Materials, Measurements and Applications, pp. 322-325, 1996.
- Gjerde, A. C. “Multifactor ageing models - origin and similarities”, *IEEE Electrical Insulation Magazine*, Vol. 13, No. 1, páginas 6-13, 1997.
- Gu, Y, Bollen, M.H.J. “Time-frequency and time scale domain analysis of voltage disturbance”, *IEEE Transaction on Power Delivery*, Vol. 15, No. 4, páginas 1279-1284, 2000.
- Gulski, E. y Kreuger, F. H. “Computer-aided Analysis of Discharge Patterns”, *Journal of Physics. D: applied. Physics*. Vol. 23, páginas 1569-1575, 1990.
- Gulski, E. “Computer-aided recognition of discharge sources”, *IEEE Transaction on Electrical Insulation*, Vol. 27, páginas 82–92, 1992.
- Gulski, E. “Computer-aided measurement of partial discharges in HV equipment”, *IEEE Transaction on Electrical Insulation*, Vol. 28, páginas 969–983, 1993.
- Gulski, E. y Krivda A. “Neural networks as a tool for recognition of partial discharge”, *IEEE Transaction on Electrical Insulation*, Vol. 28, No. 6, páginas 984-1001, 1993.

- Gulski, E. "Digital analysis of partial discharge", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 2, No 5, páginas 822-837, 1995.
- Hao, H., Lewin, P.L. "Partial discharge source discrimination using a support vector machine", IEEE Transactions on Dielectrics and Electrical Insulation, Vol.17, paginas 189–197, .2010.
- Hao, H., Lewin, P.L., Hunter, J. A., Swaffield, D.J, Contin, A., Walton C. y Michel, M. "Discrimination of multiple PD sources using wavelet decomposition and principal component analysis", IEEE Transactions on Dielectrics and Electrical Insulation, Vol.18, No. 5, páginas 1702-1711, 2011.
- Harrold, R.T. "Acoustic Theory Applied to the Physics of Electrical Breakdown in Dielectrics", IEEE Transaction on Electrical Insulation, Vol. El-21, No. 5, páginas 781-792, 1986.
- Harrold, R.T. "Acoustical Technology Applications in Electrical Insulation and Dielectrics", IEEE Transaction on Electrical Insulation, Vol. El-20, No. 1, páginas 3-19, 1985.
- Haykin, S. Neural networks and learning machines. III edición. Upper Saddle River, NJ. Pearson Education, 2009.
- Heitz, T. "A generalized model for partial discharge processes based on a stochastic process approach" Journal of Physics D: Applied Physics, Vol. 32, No. 9, páginas 1012-1023, 1999.
- Hikita, M., Okabe, S., Murase H. y Okubo, H. "Cross-equipment Evaluation of Partial Discharge Measurement and Diagnosis Techniques in Electric Power Apparatus for Transmission and Distribution", IEEE Transaction on Electrical Insulation, Vol. 15, No. 2, páginas 505-518, 2008.
- Howells, E. y Norton, E.T. "Detection of partial discharge in transformer using acoustic emission techniques", IEEE Transactions on Power Apparatus and Systems, Vol. PAS-97, No. 5, paginas 1538-1549, 1978.
- Hyvarinen, A., Karhunen, J. y Oja, E. "ICA by Maximization of Nongaussianity," en Independent Component Analysis, I edición, JOHN WILEY & SONS, Cap. 2, 2001.
- ICA y BSS group, "The FastICA software package", [online]: "http://research.ics.aalto.fi/ica/fastica/. Último acceso: 9 de septiembre del 2017.
- IEC-60270. High-Voltage Test Techniques - Partial Discharge Measurements. 3a edición, 2000.

- IEC-TS-62478. High-Voltage Test Techniques - Measurement of Partial Discharges by Electromagnetic and Acoustic Methods. Edition 1.0, 2016-08.
- IEEE C57.104-2008. IEEE Guide for interpretation of gases generated in oil-immersed transformer.
- IEEE Std C57.127TM-2007. IEEE Guide for the Detection and Location of Acoustic Emissions from Partial Discharges in Oil-Immersed Power Transformers. 2007.
- IEEE Std 1291-1993. IEEE Guide for PD Measurment in Liquid-Filled Power Transformer. 1993.
- IEEE Std C57.113-1991. IEEE Guide for the Detection and Location of Acoustic Emissions from Partial Discharges in Oil-Immersed Power Transformers. 1991.
- Jian, L., Tianyan, J., Harrison R.F. y Grzybowski, S. "Recognition of ultra high frequency partial discharge signals using multi-scale features", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 19, No 4, páginas 1412-1420, 2012.
- Jin, J., Chang, C.S., Chang, C., Hoshino, T., Hanai M. y Kobayashi, N. "Classification of partial discharge events in gas-insulated substations using wavelet packet transform and neural network approaches", IEE Proceedings-Science, Measurement and Technology, Vol. 153, No 2, páginas 55-63, 2006.
- Judd, M.D. y Farish, O. "High Bandwith Measurement of Partial Discharge Current Pulses", The International Symposium on Electrical Insulation (ISEI), Toyohashi, Japan, Vol.2, paginas 436-439, 1998
- Judd, M.D., Farish, O., Pearson, J. S. y Hampton, B.F. "Dielectric Windows for UHF partial discharge detection", IEEE Transaction on Dielectric and Electric Insulation, Vol. 8, No. 6., páginas 953-958, 2001.
- Judd, M.D., Yang L. y Hunter, I.B.B. "Partial discharge monitoring of power transformers using UHF sensors. Part I: sensors and signal interpretation", IEEE Electrical Insuation. Magazine, Vol. 21, No. 2, páginas 5-14, 2005.
- Kimura, H., Tsumura, T. y Yokosuka, M. "Coronain Oil as Part of Commercial-Frequency Circuit," Electrotechnical Journal of Japan, Vol. 4, páginas 90-92, 1940,
- Kranz, H. "Diagnosis of partial discharge signals using neural networks and minimum distance classification", IEEE on Transaction Dielectric Electrical Insulation, Vol. 28, No. 6, páginas 1016-1024, 1993.
- Kreuger, F.H, Gulski, E. y Krivda, A. "Classification of partial discharge", IEEE on Transaction Dielectric Electrical Insulation, Vol.28, No. 6, páginas 917-931, 1993

- Krivda, A. "Automated recognition of partial discharges", IEEE on Transaction Dielectric Electrical Insulation, Vol. 2, No 5, páginas 796-821, 1995.
- Kundu, P., Kishore, N.K. y Sinha, A.K. "Identification of two simultaneous partial discharge sources in an oil-pressboard insulation system using acoustic emission techniques", Applied Acoustic, Vol. 73, No 4, páginas 395-401, 2012.
- Kweon, D.J., Chin, S.B., Kwak, H.R., Kim, J.C. y Song, K. B "The analysis of ultrasonic signals by partial discharge and noise from the transformer", IEEE Power Delivery, Vol. 20, No. 3, páginas 1976-1983, 2005.
- Lathauwer, L., Moor, B. y Vandewalle, J. "Fetal electrocardiogram extraction by blind source subspace separation", IEEE Transactions on Biomedical Engineering 47 (2000) 567–572.
- Latitha, E.M. y Satish, L. "Wavelet analysis for classification of multi-source PD patterns", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7, No 1, páginas 40-47, 2000.
- Laurent, C. y Mayoux, C. "Partial Discharge-Part XI: Limitations to PD as a Diagnostic for Deterioration and Remaining Life", IEEE Electrical Insulation Magazine, Vol. 8, No. 2, pp. 14-17, 1992.
- Lemke, E., Berlijn, S., Galski, E., Muhr, M., Pultrum, E., Strehl, T., Hauschild, W. y Rickmann, J. Guide for partial discharge measurements in compliance to IEC 60270. 2008.
- Levenberg, K., "A Method for the Solution of Certain Problems in Least-Squares," Quarterly Applied Math. 2, pp. 164–168, 1944.
- Li, X., Li, C., Wang, W., Wan, W. y X. Shen, "Application of UHF on partial discharge detection in generator stator bar", Proceedings of the 2004 IEEE International Conference on Solid Dielectric, Vol. 2, páginas 676-678, 2004.
- Lima, M. AA., Cerqueira, A. S, Coury, D. V. y Duque, C. A. "A novel method for power quality multiple disturbance decomposition based on Independent Component Analysis." International Journal of Electrical Power & Energy Systems 42.1 (2012): 593-604.
- Loghmani, M.A., Naceur M.S. y Boussema, M.R. "A Spectral and Spatial Source Separation of Multispectral Images", IEEE on Trans. Geoscience. and Remote Sensing, Vol. 44, No. 12, páginas. 3659-3673, 2006.
- Lombard, A, Zheng, Y., Buchner, H. y Kellermann, W. "TDOA Estimation for Multiple Sound Sources in Noisy and Reverberant Environments Using Broadband

- Independent Component Analysis” IEEE Transactions on Audio, Speech, and Language Processing 19.6 (2011): 1490-1503.
- Lu, Y., Tan, X. y Hu, X. “PD detection and localization by acoustic measurements in an oil-filled transformer”, IEE Proceedings Science, Measurement and Technology, Vol. 147, No. 2, páginas 81-85, 2000.
- Lundgaard, L.E. “Partial discharge. XIII. Acoustic partial discharge detection-fundamental considerations”, IEEE Electrical Insulation Magazine, Vol. 8, No. 4, páginas 25-31, 1992a.
- Lundgaard, L.E. “Partial discharge. XIV. Acoustic partial discharge detection-practical application”, IEEE Electrical Insulation Magazine, Vol. 8, No. 5, páginas 34-43, 1992b.
- Makeig, S., Bell, A.J., Jung, T.-P. y Sejnowski, T.J., Independent component analysis of electroencephalographic data, Advances in Neural Information Processing Systems 8 (1996) 145–151.
- Malik, N.H., Al-Arainy, A.A. y Qureshi, M. I., Electrical insulation in Power Systems. Primera edición, MARCEL DEKKER, New York, Cap. 1, 1998.
- Marquardt, D., "An Algorithm for Least-Squares Estimation of Nonlinear Parameters," SIAM Journal Applied Math., Vol. 11, pp. 431–441, 1963.
- Ruiz-Llata, M., Guarnizo, G. y Boya, C. “Embedded power quality monitoring system based on Independent Component Analysis and SVMs”, The 2011 International Joint Conference on Neural Networks (IJCNN), páginas 2229-2234, San Jose, California, 2011.
- Mazroua, A., Salama, M y Bartnikas “PD pattern recognition with neural networks using the multilayer perceptron technique”, IEEE Transactions on Electrical Insulation, Vol. 28, páginas 1082-1089, 1993.
- Mazroua, A., Bartnikas, R. y Salama, M. “Discrimination between PD pulse shapes using different neural network paradigms”, IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 1, No.6, páginas 1119-1131, 1994.
- Montanari, G. C., Cavallini, A. y Puletti, F. “A new approach to partial discharge testing of HV cable systems”, IEEE Electrical Insulation Magazine, Vol. 22, No. 1, páginas 14-23, 2006.
- Moore, P.J., Portugues, I.E. y Glover, I.A. “Radiometric location of partial discharge sources on energized high-Voltage plant”, IEEE Power Delivery, Vol. 20, No. 3, páginas 2264-2272, 2005.

- Morshuis, P. “Degradation of solid dielectrics due to internal partial discharge: some thoughts on progress made and where to go now,” IEEE Transactions on Dielectrics and Electrical Insulation, vol. 12(5), páginas 905 – 913, 2005.
- Morshuis, P. y Smit, J.J. “Partial Discharges at dc Voltage: Their Mechanism, Detection and Analysis,” IEEE Transactions on Dielectrics and Electrical Insulation, vol. 12, No.5, páginas 328 – 340, 2005.
- Morshuis, P. Partial Discharge Mechanisms. Delft University Press, Netherlands, 1993.
- Morshuis, P., Montanari, G.C. y Fornasari, “Partial discharge diagnostics — Critical steps towards on-line monitoring”, En 2014 IEEE PES T&D Conference and Exposition, paginas 1-5, 2014.
- Muhr, M., Strehl, T., Galski, E., Feser, Gockenbach, E. y Hauschild, W. Sensors And Sensing Used For Non-Conventional PD Detection, Ref No: DI-102, Cigré, 2006.
- Nguyen Thi, H.-L. y Jutten, C “Blind source separation for convolutive mixtures”, Signal Processing 45 (1995) 209–229.
- Orr, P. J. G., Reid, A. J. y Judd, M. D. “Sensor response characteristics for UHF location of PD sources”, Conference on Condition Monitoring and Diagnosis, Beijing, China, paginas 1119 – 1122, 2008.
- Oja, E., “Applications of independent component analysis”, International conference on neural information, Calcutta, India, páginas 1044-1051, 2004.
- Okamoto, T., Kato, T., Yokomizu, Y. y Suzouki, Y. “PD characteristics as a stochastic process and its integral equation under sinusoidal voltaje”, IEEE Transactions on Dielectrics and Electrical Insulation, vol. 8, No.1, páginas 82 – 90, 2001.
- Papoulis, A., y Pillai, S. U. *Probability, random variables, and stochastic processes*. Tata McGraw-Hill Education, (2002).
- Portugues, I.E, Moore, P.J., Glover, I.A., Johnstone, C., McKosky, R.H., Goff M.B y van der Zel, L. “RF-Based Partial Discharge Early Warning System for Air-Insulated Substations”, IEEE transaction on Power Delivery, Vol., No. 1, páginas 20-29, 2009.
- Posada, J.E., Garcia-Souto J.G., y Rubio-Serrano, J. “Multichannel optical-fibre heterodyne interferometer for ultrasound detection of partial discharges in power transformers”, Measurement. Science and Technology, Vol. 24, No. 9, 2013.
- Posada-Roman, J., Garcia-Souto, J. y Rubio-Serrano, J. “Fiber Optic Sensor for Acoustic Detection of Partial Discharges in Oil-Paper Insulated Electrical Systems”, Sensors, Vol.12, No. 1, páginas 4793-4802, 2012

- Ramírez-Niño, J. y Pascacio, A. "Acoustic measuring of partial discharge in power transformers", *Measurement, Science, and Technology*, Vol. 20, No. 11, 2009.
- Rebsamen, B., Guan, C., Zhang, H., Wang, C., Teo, C., Ang Jr, M. H. y Burdet, E. "A brain controlled wheelchair to navigate in familiar environments.", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(6), 590-598, 2010.
- Reid, A. J., Judd, M. D., Stewart, B. G. y Fouracre, R. A. "Partial discharge current pulses in SF6 and the effect of superposition of their radiometric measurement", *Journal of Physics D: Applied Physics*, Vol. 39, No. 19, páginas 1012-1023, 2006.
- Rizzi, A., Mascioli, F. M. F., Baldini, F., Mazzetti, C. y Bartnikas, R. "Genetic optimización of a PD diagnostic system for cable accessories", *IEEE Transaction on Power Delivery* Vol. 24, No. 3, páginas 1728-1738, 2009.
- Robles, G., Sanchez-Fernandez, M., Albarracín, R., Rojas-Moreno, M.V., Rajo-Iglesias, E. y Martínez-Tarifa, J.M. "Antenna Parametrization for the Detection of Partial Discharges", *IEEE Transaction on Instrumentation and Measurement*, Vol. 62, No. 5, paginas 932-941, 2013.
- Ross, S. M. "Distributions of sampling statistics," en *Probability and statistics for engineers and scientists*, III edicion, E. A. PRESS, 2004.
- Rubio-Serrano, J., Rojas-Moreno, M. V., Posada, J., Martinez-Tarifa, J.M., Robles, G. y Garcia-Souto, J.A. "Electro-acoustic detection, identification and location of partial discharge sources in oil-paper insulation systems", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 19, No.5, páginas 1569 – 1578, 2012.
- Sarathi, R., Nandini, A. y Tanaka, T. "Understanding electrical treeing phenomena in XLPE cable insulation under harmonic AC voltages adopting UHF technique", *IEEE Transaction Dielectric Electrical Insulation*, Vol. 19, No 3, páginas 903-909, 2012.
- Sahoo, N. C., Salama, M.M.A y Bartnikas, R. "Trends in partial discharge pattern classification a survey", *IEEE Transactions on Dielectrics and Electrical Insulation*, , Vol. 12, No. 2, páginas 248-264, 2005.
- Salama, M. y Bartnikas, R. "Fuzzy logic applied to PD pattern classification", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 7, No. 1, páginas 118-123, 2000.
- Schau, H. C. y Robinson, A. Z. "Passive source localization employing intersecting spherical surfaces from time-of-arrival differences", *IEEE Transaction on*

- Acoustic, Speech and Signal Processing, Vol. ASSP-35, No. 8, páginas 1223-1225, 1987.
- Sharkawy R. M., Mangoubi, R.S., Abdel-Galil, T., Salama, M.M.A., Bartnikas, R. "SVM classification of contaminating particles in liquid dielectric using higher order statistics of electrical and acoustic PD measurements", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 14, No. 3, páginas 669-678, 2007.
- Shibuya, Y., Matsumoto, S., Tanaka, M., Muto H. y Kaneda, Y. "Electromagnetic waves from partial discharges and their detection using patch antenna", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 17, No 3, páginas 862-871, 2010.
- Shih, J. J., Krusienski, D. J. y Wolpaw, J. R. Brain-computer interfaces in medicine. In Mayo Clinic Proceedings (Vol. 87, No. 3, pp. 268-279), 2012.
- Sinaga, H. H., Phung, B. T., Ao, P. L. y Blackburn, T. R. "Partial Discharge Localization in Transformers Using UHF Sensors", Electrical Insulation Conference (EIC), Anneapolis, USA, 2011.
- Sinaga, H.H. Detection, identification and localization of partial discharges in power transformer using UHF techniques, PhD Thesis, The University of New South Wales, Australia, 2012a.
- Sinaga, H.H., Phung, B.T. y Blackburn, T.R. "Partial discharge localization in transformers using UHF detection method", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 19, No 6, páginas 1891-1900, 2012b.
- Sriram, S., Nitin, S., Prabhu, K.M.M. y Bastiaans M.J. "Signal Denoising Techniques for Partial Discharge Measurements", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 12, No 6, páginas 1182-1191, 2005.
- Stone, G.C. "Partial discharge diagnostics and electrical equipment insulation condition assessment", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 12, No. 5, páginas 891-904, 2005.
- Tanaka T. y Okamoto, T. "A minicomputer based partial discharge measurement system", 1978 IEEE Int. Symp. on Electr. Insul., Conf., Philadelphia, 1978, páginas 86-89.
- Tanaka, T. "Internal Partial Discharge and Material Degradation," IEEE Transactions on Electrical Insulation, Vol. EI-21, No. 6, páginas 899-905, December 1986.
- Tang, Ju., Li, W. y Liu, Y. "Blind Source Separation of Mixed PD Signals Produced by Multiple Insulation Defects in GIS", IEEE Transaction on Power Delivery, Vol. 25, No.1, páginas 170-176, 2010.

- Tang, A.C., Pearlmutter, B.A., Malaszenko, N.A., Phung, D.B. y Reeb, B.C. Independent components of magnetoencephalography: Localization, Neural Computation 14 (2002) 1827–1858.
- Tian, Y., Lewin, P.L., Davies, A.E. y Richardson, Z. “PD pattern identification using acoustic emission measurement and neural networks”, Eleventh International Symposium on High Voltage Engineering, London, Vol.5, paginas 41-44, 1999.
- Tian, Y., Lewin, P.L., Sutton S.J. y Swingler, S.G. “PD characterization using short duration Fourier transform of acoustic emission signals”, Proceedings of the 2004 IEEE International Conference on Solid Dielectrics, Toulouse, Vol.2, páginas 695-698, 2004a.
- Tian, Y., Lewin, P.L., Sutton S.J. y Swingler, S.G. “PD characterization using wavelet decomposition of acoustic emission signals”, Proceedings of the 2004 IEEE International Conference on Solid Dielectrics, Toulouse, Vol.2, páginas 699-702, 2004b.
- Tonieri, D. J. “Statistical theory of passive location systems”, IEEE Transaction on Aerospace Electronic System, Vol. AES-20, páginas 183-198, 1984.
- Wadhwa, C.L, “High voltaje engineering”, segunda edicion, NEW AGE INTERNATIONAL LIMITED, New Delhi, India, 2007.
- Wenrong, S., Junhao, Li, Peng, Y. y Yanming L. “A New Approach to Extract PD Pulse using Independent Component Analysis”, en IEEE international symposium on electrical insulation, Vancouver, Canada, páginas 351-354, 2008.
- Van Brunt, R. J. “Physics and chemistry of partial discharge and corona - recent advances and future challenges”. En IEEE Conference on Electrical Insulation and Dielectric Phenomena, 1994. Páginas 29-70, 1994.
- Van Brunt, R. J. “Stochastic properties of partial-discharge phenomena”. En IEEE Transactions on Electrical Insulation, Vol. 26, No. 5, Páginas 902-948, 1991.
- Vetter, R., Virag, N., Vesin, J.M., Celka, P. y Scherrer, U. “Observer of autonomic cardiac outflow based on blind source separation of ECG parameters”, IEEE Transactions On Biomedical Engineering 47 (2000) 578–582.
- Vigario, R. Extraction of ocular artefacts from EEG using independent component analysis, Electroencephalography Clinical Neurophysiology 103 (1997) 395–404.
- Yang, L. y Judd, M.D. “Recognising multiple partial discharge sources in power transformers by wavelet analysis of UHF signals”, IEE Proceedings-Science, Measurement and Technology, Vol. 150, No 3, páginas 119-127, 2003.

Ziomek, W., Reformat, M. y Kuffel, E. "Application of genetic algorithms to pattern recognition of defects in GIS". IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7, No. 2, páginas 161-168, 2000.